

FACULDADE DE ENGENHARIA DA UNIVERSIDADE DO PORTO



**Processamento de imagens térmicas  
para a avaliação do risco de pé diabético  
- *Backoffice***

**Lúcia Vaz**

Mestrado Integrado em Engenharia Eletrotécnica e de Computadores

Orientador: Prof. Dr. Ricardo Vardasca

Coorientador: Prof. Dr. Joaquim Mendes

20 de Julho de 2017



# Resumo

Atualmente, em Portugal, estima-se que mais de um milhão de indivíduos padeçam da doença metabólica *Diabetes Mellitus* (DM). Deste conjunto de indivíduos, cerca de um quarto pode desenvolver uma complicação dada pelo nome de pé diabético (*Diabetic Foot Ulcer* - DFU) que se manifesta com o aparecimento de uma ou mais úlceras na região do pé. Dependendo da sua natureza (neuropática, neuroisquémica ou isquémica), estas úlceras surgem em zonas onde ocorre uma pressão, por o indivíduo se movimentar ou pelo uso de calçado desadequado. Numa fase inicial, um dos primeiros sinais desta patologia é o aumento da temperatura e, sendo a termografia uma técnica que permite obter imagens com os valores de temperaturas existentes na superfície dos objetos capturados, é possível detetar o desenvolvimento desta patologia através de imagens térmicas infravermelhas do pé. Anteriormente, em projetos da FEUP, foram recolhidas imagens de pacientes, indivíduos em grande risco e em pessoas saudáveis, que comprovaram a utilidade da técnica de termografia.

A finalidade da presente dissertação é criar uma ferramenta mais avançada de análise e classificação de dados, de forma a reduzir o erro humano e sistematizar o uso desta técnica. Neste sentido, pretendeu-se adaptar técnicas utilizadas em análise inteligente de dados (*Data-Mining*), mais especificamente métodos de classificação de dados provenientes da área de aprendizagem automática (*Machine Learning*). Com o sucesso desta adaptação, é possível identificar, através da classificação, a existência de úlceras nas imagens térmicas do pé.

A ferramenta informática desenvolvida nesta dissertação é constituída pela criação de dois programas na linguagem C# e pelo armazenamento, numa base de dados (BD), de análises e informações extraídas dos ficheiros de imagens térmicas recolhidos em projetos anteriores realizados na FEUP. O sistema desenvolvido pode ser dividido em cinco partes principais, sendo elas a localização e extração de metadados em ficheiros binários, processamento de imagens, identificação das regiões de interesse (ROI), estruturação e povoamento da base de dados, e por último, desenvolvimento de ferramentas que permitam a classificação. Para que no final fosse realizada uma análise quanto à qualidade dos resultados obtidos nos testes de classificação, foi realizada, em paralelo e com os mesmos dados, classificação com o *software* Weka.

Ao longo do desenvolvimento da dissertação, foram abordados vários métodos a fim de serem obtidos os melhores resultados. Foram encontrados alguns obstáculos que desencadearam abordagens alternativas e a implementação de mais métodos. Os resultados obtidos são satisfatórios e cumprem com a finalidade proposta. O melhor resultado obtido com o programa desenvolvido para a classificação apresenta um valor percentual de exatidão arredondado para 93% e foi obtido utilizando o programa desenvolvido e o classificador KNN (*K-Nearest Neighbor*).

O resultado final disponibiliza aplicações informáticas que no futuro poderão ser aprofundadas para apoiar no rastreio e seguimento de pacientes em risco de desenvolver pé diabético.

Palavras chave: Classificação; Pé diabético; Termografia; Úlceras.



# Abstract

Currently in Portugal, an estimated one million people are affected by *Diabetes Mellitus* (DM), a metabolic disorder commonly referred to as diabetes. Of this group of people, nearly 25% of them can develop serious skin issues such as diabetic foot ulcers (DFU) in their lifetime. This complication expresses itself by the appearance of one or multiple ulcers in the foot area. Depending on its nature (Neuropathic, Neuro-ischemic or Ischemic), these ulcers appear on high pressure zones of the foot, either because of the patients' movement or inadequate footwear. In an initial phase, one of the first symptoms of this pathology is the increase of skin temperature. Thermography is a technique that allows the acquisition of images with the temperature values of the surface of the framed objects, which allows the early detection of DFUs through the analysis of thermal infrared images of the foot. In earlier projects developed at FEUP, a set of images was gathered from patients, high risk individuals and healthy people which demonstrated the usefulness of thermography.

The purpose of this dissertation is to design an advanced tool of analysis and data classification as a way to reduce human error and standardize the use of this technique. With this aim, it was intended to adapt intelligent data mining procedures, specifically, data classification methods originally used in the machine learning field of study. With a successful adaptation of these methods, it is possible to identify the existence of early signs of diabetic foot ulcers in thermal images.

The computational tool developed in this dissertation is assembled by two programs developed using the C# language and by the storage, in a relational database, of all analysis made and information extracted from the thermal images. The developed system can be subdivided into five main parts, which are the localization and extraction of metadata from the binary files, the image processing, the identification of the regions of interest (ROI), the database structure definition and data entry, and the development of the classification tool. In order to evaluate the quality of the results obtained in the classification tests, another set of tests was carried out in parallel, with the same data and using the Weka software.

Throughout the development of the various parts of this work, an additional research work was performed about which methods should be used in order to obtain the best possible results. The appearance of several issues and obstacles led to alternative approaches and the development of different methods. The final results are satisfactory and achieve the proposed objectives. The best results achieved in a classification test, using the KNN classifier, presented an accuracy of 93%.

Therefore, the final result is a set of tools that, in the future, can be used to support the early detection and follow-up of patients in risk of developing diabetic foot ulcers.

Keywords: Classification; Diabetic foot; Thermography; Ulcers.



# Agradecimentos

Para não “fugir à regra”, deixo aqui alguns agradecimentos que não poderia deixar de fazer.

Em primeiro lugar, às pessoas que mais tiveram influência no desenvolvimento desta dissertação, quero agradecer ao Professor Ricardo Vardasca e ao Professor Joaquim Gabriel, por terem proposto um tema de dissertação tão desafiante e por terem tido sempre sugestões ou alternativas a dar quando algum obstáculos surgia.

Gostava de demonstrar o apreço, que me foi sugerido, pelo projeto NORTE-01-0145-FEDER-000022 - SciTech - Science and Technology for Competitive and Sustainable Industries, co-financiado pelo Programa Operacional Regional do Norte (NORTE2020), financiado pelo Fundo Europeu de Desenvolvimento Regional (FEDER) e pela FCT – Fundação para a Ciência e Tecnologia sobre o projeto (PEst-OE/EME/LA0022/2013).

Às pessoas do L003 quero agradecer pelo ambiente de trabalho proporcionado. Um obrigado em especial à Joana Tavares, à Rita Almeida e a Joana Moreira pelos momentos passados.

Às outras pessoas que de uma forma não direta contribuíram para o sucesso desta dissertação, obrigada. Em especial, à Inês Teixeira por me ter emprestado um pouco da sua infinita criatividade. Ao João Silva, por me fazer ver as coisas de um modo diferente. À Daniela Carmo, à Ângela Torres e ao Sérgio Pinto pela paciência, pelas conversas, disponibilidade, coffee breaks, coisas e tais. A todos, obrigada por estes anos.

Aos meus amigos de toda a vida e aos meus quase-médicos de eleição, obrigada pela amizade, conselhos, orientações mas também pelo bom humor e por todos os momentos partilhados. À Mariana Martins um obrigado extra pelo tempo disponibilizado.

Ao Filipe Monteiro, não existem palavras suficientes para poder agradecer por tanto. Assim sendo, apenas posso dizer obrigada por tudo, por mais alguma coisa, por tudo o resto e pelo que ainda não ficou incluído.

À minha família, um obrigado por tudo o que têm “aturado” nestes últimos meses. À Isabel Vila e Leonor Vila um obrigada extra por conseguirem renovar-me a motivação e mostrarem-me como se pode fazer o bem com pouco. À Susana Barroso, obrigada pela preocupação e disponibilidade mesmo em épocas mais complicadas da vida e a centenas de quilómetros de distância.

Há pessoas a quem agradecer não é suficiente porque, mesmo sem o saberem e sem nunca o terem imaginado, contribuíram demasiado para merecerem meros agradecimentos. Aos meus pais dedico esta dissertação.

A todos, Obrigada!

Lúcia Vaz





*“A picture can tell a thousand words,  
but a few words can change its story.”*

— Sebastyne Young



# Conteúdo

<b>1</b>	<b>Introdução</b>	<b>1</b>
1.1	Contexto . . . . .	1
1.2	Motivação . . . . .	3
1.3	Finalidade . . . . .	3
1.4	Objetivos . . . . .	4
1.5	Estrutura da dissertação . . . . .	4
<b>2</b>	<b>Estado da arte</b>	<b>7</b>
2.1	Fundamentos da termografia . . . . .	7
2.1.1	Conceitos fundamentais de energia Térmica . . . . .	7
2.1.2	Evolução da termografia . . . . .	11
2.1.3	Aquisição e recolha de termogramas . . . . .	12
2.1.4	Termografia aplicada ao pé diabético . . . . .	13
2.2	Formatos de imagens térmicas . . . . .	15
2.2.1	Formatos dos Ficheiros . . . . .	15
2.2.2	Extensões de metadados . . . . .	15
2.2.3	Aplicação <i>ExifTool</i> . . . . .	15
2.2.4	Fórmula de cálculo de temperatura em imagens térmicas . . . . .	16
2.3	Técnicas de processamento de imagem . . . . .	16
2.3.1	Pré-processamento . . . . .	16
2.3.2	Segmentação . . . . .	17
2.4	Regiões de interesse para a deteção do pé diabético . . . . .	18
2.5	Sistemas de gestão de base de dados . . . . .	20
2.6	Sumário . . . . .	20
<b>3</b>	<b>Revisão do uso de classificadores em termografia</b>	<b>23</b>
3.1	Método para a avaliação de um classificador . . . . .	23
3.1.1	Métricas para a <i>performance</i> . . . . .	24
3.1.2	<i>Receiver operating characteristic</i> (ROC) . . . . .	24
3.2	Redes Neurais . . . . .	24
3.2.1	Definição . . . . .	24
3.2.2	Utilização na termografia . . . . .	27
3.3	Redes Bayesianas . . . . .	30
3.4	<i>Support Vector Machine</i> . . . . .	31
3.4.1	Definição . . . . .	31
3.4.2	Utilização na termografia . . . . .	32
3.5	<i>K-nearest neighbor</i> . . . . .	33
3.6	WEKA . . . . .	34

3.7	Sumário . . . . .	34
<b>4</b>	<b>Design e especificações do sistema</b>	<b>37</b>
4.1	Requisitos do sistema . . . . .	37
4.2	Arquitetura do sistema . . . . .	39
4.3	Sumário . . . . .	40
<b>5</b>	<b>Processamento de informação</b>	<b>43</b>
5.1	Localização dos metadados em ficheiros Binários . . . . .	43
5.2	Processamento de imagens . . . . .	44
5.2.1	Método 1 . . . . .	44
5.2.2	Método 2 . . . . .	48
5.3	Identificação de ROIs . . . . .	48
5.3.1	Determinação da localização de cada ROI . . . . .	48
5.3.2	Determinação de valores de temperatura . . . . .	49
5.4	Sumário . . . . .	50
<b>6</b>	<b>Gestão da base de dados e classificação</b>	<b>51</b>
6.1	Estrutura da base de dados . . . . .	51
6.2	Classificação . . . . .	52
6.2.1	Programa desenvolvido para a classificação . . . . .	52
6.3	Sumário . . . . .	54
<b>7</b>	<b>Resultados</b>	<b>55</b>
7.1	Localização dos metadados e leitura binária dos ficheiros . . . . .	55
7.1.1	Ficheiros com o formato .img . . . . .	55
7.2	Processamento de imagem . . . . .	59
7.2.1	Método de segmentação . . . . .	59
7.3	Identificação de ROIs . . . . .	62
7.4	Base de dados . . . . .	63
7.5	Classificação . . . . .	64
7.5.1	Representação bi-dimensional dos dados . . . . .	64
7.5.2	Resultados da classificação . . . . .	65
7.6	Imagens dos programas desenvolvidos em C# . . . . .	66
7.6.1	Programa 1 . . . . .	66
7.6.2	Programa 2 . . . . .	68
7.7	Sumário . . . . .	68
<b>8</b>	<b>Discussão</b>	<b>69</b>
8.1	Localização dos metadados e leitura binária dos ficheiros . . . . .	69
8.1.1	Em ficheiros com o formato .img . . . . .	69
8.1.2	Em ficheiros com o formato .jpg . . . . .	70
8.2	Processamento de imagem . . . . .	70
8.3	Identificação de ROIs . . . . .	71
8.4	Base de dados . . . . .	71
8.5	Classificação . . . . .	72
8.6	Sumário . . . . .	73
<b>9</b>	<b>Conclusão</b>	<b>75</b>

<b>Referências</b>	<b>77</b>
<b>A Informações <i>metadata</i></b>	<b>83</b>
<b>B Resultados da ferramenta <i>ExifTools</i></b>	<b>87</b>
B.1 Em ficheiros .img . . . . .	87
B.2 Em ficheiros .jpg radiométrico . . . . .	88
<b>C Scripts de código <i>SQL</i> da criação das tabelas de base de dados</b>	<b>93</b>
<b>D Resultados dos dados calculados nas ROIs</b>	<b>97</b>
D.1 Em graus Celcius . . . . .	97
D.2 Em graus radiométricos . . . . .	115
<b>E Resultados da classificação obtidos com o programa desenvolvido</b>	<b>135</b>
E.1 Primeiro teste de KNN . . . . .	135
E.2 Segundo teste de KNN . . . . .	138
E.3 Terceiro teste de KNN . . . . .	141
<b>F Resultados da classificação obtidos com o programa Weka</b>	<b>145</b>
F.1 Primeiro teste de KNN . . . . .	145



# Lista de Figuras

1.1	Exemplo de imagens térmicas para cada um dos tipos de úlcera. Imagem retirada de [1] . . . . .	2
2.1	Espectro eletromagnético relacionado com a energia térmica . . . . .	8
2.2	Representação da distribuição de Planck para os vários comprimentos de onda, adaptado de [2] . . . . .	9
2.3	Representação da lei de deslocamento de Wien . . . . .	10
2.4	Espectro eletromagnético e sua utilização, retirado de [2] . . . . .	12
2.5	Exemplo de um histograma bimodal [3] . . . . .	18
2.6	Regiões de Interesse utilizadas[4] . . . . .	18
2.7	Regiões de Interesse utilizadas para a caracterização [2] . . . . .	19
2.8	Distribuição dos tipos de úlceras pelas regiões de interesse [2] . . . . .	19
3.1	Exemplo de uma curva ROC . . . . .	25
3.2	Arquitetura de uma rede ANN criada[5] . . . . .	25
3.3	Sistema de Previsão . . . . .	26
3.4	Exemplo de um grafo orientado e acíclico . . . . .	30
3.5	Exemplo da representação de um SVM. . . . .	32
3.6	Representação das conclusões na revisão de classificação . . . . .	35
4.1	Arquitetura do sistema implementado . . . . .	40
5.1	Diagrama de atividade para a leitura de imagens térmicas . . . . .	44
5.2	Diagrama de atividade para o processamento e segmentação de imagens térmicas . . . . .	45
5.3	Exemplo de um histograma obtido . . . . .	46
5.4	Offset percentual entre os valores os valores de mínimo e média da temperatura . . . . .	46
5.5	Esboço de construção de um pé de Albrecht Dürer, 1513 [6] . . . . .	47
5.6	Localização das ROIs e dos pontos auxiliares . . . . .	48
5.7	Diagrama de atividade para determinação da posição do píxel central de cada ROI . . . . .	49
6.1	Modelo relacional para os elementos de treino da classificação . . . . .	51
6.2	Modelo Relacional para os elementos de treino da classificação . . . . .	52
6.3	Diagrama de atividade para a implementação do classificador KNN . . . . .	53
7.1	Conteúdo dos primeiros 20 bytes dos ficheiros com o formato .img . . . . .	55
7.2	Primeiro conjunto de tags encontradas . . . . .	56
7.3	Segundo conjunto de tags encontradas . . . . .	56
7.4	Terceiro conjunto de tags encontradas . . . . .	56
7.5	Quarto conjunto de tags encontradas . . . . .	57

7.6	Quinto conjunto de <i>tags</i> encontradas . . . . .	57
7.7	Exemplo da imagem obtida com a leitura dos valores da matriz radiométrica . . .	57
7.8	Exemplo de imagens obtidas obtidas a partir da separação no formato .jpg . . . .	58
7.9	Imagem padrão do formato jpg . . . . .	58
7.10	Diagrama Detecção Automática . . . . .	59
7.11	Diagrama por Overlay . . . . .	59
7.12	Histograma da figura 7.12 . . . . .	60
7.13	Resultados obtidos na Binarização com valores diferentes para o limiar . . . . .	60
7.14	Outros resultados obtidos na Binarização . . . . .	61
7.15	Limites exteriores e em falta no dorso dos pés. . . . .	61
7.16	Área recuperada e limites de área em falta . . . . .	61
7.17	Algumas representações bi-dimensionais obtidas . . . . .	64
7.18	<i>Screenshot</i> do primeiro programa . . . . .	67
7.19	<i>Screenshot</i> do método de <i>overlay</i> . . . . .	67
7.20	<i>Screenshot</i> do segundo programa . . . . .	68



# Lista de Tabelas

1.1	Classificação de Úlcera de Meggitt-Wagner. [7]	2
2.1	<i>Ranking</i> adaptado da atualização de Junho de 2017[8]	20
2.2	Detalhes de cada DBMS	20
4.1	Requisitos funcionais do sistema	38
4.2	Requisitos não funcionais do sistema	39
7.1	Resultados da tabela public.utente presente na base de dados	63
7.2	Numero de elementos inseridos na BD	63
7.3	Resultados para o primeiro teste	65
7.4	Resultados obtidos no programa WEKA	66
7.5	Resultados obtidos no programa desenvolvido para o classificador KNN	66
A.1	Informação retirada da extensão .FFF[9]	83
A.2	Informação contida na <i>Tag CameraInfo</i> da extensão .FFF	84
A.3	Informação retirada da extensão .FPF	85
B.1	Resultados obtidos com a aplicação de <i>ExifTool</i> para uma imagem térmica do tipo .img	87
B.2	Resultados obtidos com a aplicação de <i>ExifTool</i> para uma imagem térmica do tipo .jpg radiométrico	88



# Abreviaturas

AI	<i>Artificial Intelligence</i>
ANN	<i>Artificial Neural Network</i>
AUC	<i>Area Under the ROC Curve</i>
BD	Base de Dados
BN	<i>Bayesian Network</i>
BP	<i>BackPropagation</i>
DBMS	<i>DataBase Management Systems</i>
DFU	<i>Diabetic Foot Ulcer</i>
DICOM	<i>Digital Imaging and Communicatons in Medicine</i>
DM	<i>Diabetes Mellitus</i>
DN	<i>dynamic neural network</i>
FEUP	Faculdade de Engenharia da Universidade do Porto
FN	Falso Negativo
FP	Falso Positivo
ID	<i>IDentification</i>
IGR	<i>Information Gain Ratio</i>
IMC	Índice de Massa Corporal
IR	<i>Infrared Radiation</i>
IRT	<i>InfraRed Thermography</i>
KNN	<i>K-Nearest Neighbor</i>
LDA	<i>Linear Discriminant Analysis</i>
MITI	<i>Medical Infrared Thermal Imaging</i>
NDA	<i>Nonparametric discriminant analysis</i>
PCA	<i>Principal Component Analysis</i>
ROC	<i>Receiver Operating Characteristic</i>
ROI	<i>Regions of Interest / Região de Interesse</i>
SI	Sistema Internacional de unidades
SVM	<i>Support Vector Machine</i>
VN	Verdadeiro Negativo
VP	Verdadeiro Positivo
WEKA	Waikato Environment for Knowledge Analysis



# Capítulo 1

## Introdução

Este capítulo tem o objetivo de introduzir o trabalho realizado no desenvolvimento desta dissertação do Mestrado Integrado em Engenharia Eletrotécnica e de Computadores.

### 1.1 Contexto

O problema do pé diabético pode ser entendido como uma complicação associada à doença metabólica de *Diabetes Mellitus* (DM) que se manifesta com o aparecimento de úlcera na região do pé (*DFU - Diabetic Foot Ulcer*) que ocorrem normalmente em zonas onde existe uma pressão aumentada, ou seja, pelo uso de calçado desadequado ou áreas do pé onde se aplica mais força ao andar.

Segundo o relatório elaborado pela Sociedade Portuguesa de Diabetologia [10] no ano de 2014 a prevalência estimada da doença metabólica de Diabetes na população portuguesa foi de 13,1%, o que significa que, mais de 1 milhão de portugueses tem DM. Um em cada quatro destes indivíduos podem desenvolver complicações associadas a úlceras. Este problema assume importância num quadro clínico devido à influência altamente negativa que provoca na qualidade de vida do doente e dos seus familiares. Isto acontece devido ao elevado grau de dependência de terceiros a que os doentes ficam sujeitos. Em alguns casos, após o diagnóstico do pé diabético são necessários meses de tratamento e eventualmente a pessoa acabará por sofrer amputação parcial ou total do membro afetado no caso mais grave[11].

Existem três tipos de úlceras no pé diabético: neuropáticas, isquémicas e neuroisquémicas. No primeiro tipo, ocorreu um aumento prolongado da glicose assim como mudanças sensoriais e motoras. Por um lado, a neuropatia sensorial leva à perda da sensibilidade no pé enquanto que a neuropatia motora pode provocar deformidades do pé, perda de gordura na região plantar do pé, deformação nas articulações e outros danos associados. Por este motivo, neste tipo de úlceras existe um aumento da temperatura em relação à média do pé. Por outro lado, nas úlceras isquémicas existe uma doença vascular periférica que provoca uma obstrução ou alteração no normal fluxo sanguíneo nas extremidades do pé, o que leva à diminuição da temperatura nas regiões onde

exista úlcera. Contudo, são raros os casos de existência deste tipo de úlceras puramente isquémicas sendo mais comum a existência de úlceras neuroisquémicas, ou seja, com natureza isquémica e neuropática [12]. A figura 1.1 apresenta através de imagens térmicas um caso de cada tipo de úlcera.




Figura 1.1: Exemplo de imagens térmicas para cada um dos tipos de úlcera. Imagem retirada de [1]

Estas 3 capturas estão incluídas num conjunto de imagens recolhidas no decorrer de uma dissertação realizada na FEUP pela Ana Rita Soares Marques[1] com o título “Diabetic foot thermophysiology characterization” e que teve como objetivo a caracterização do pé diabético por termografia.

Uma úlcera pode ser classificada em seis graus de gravidade consoante o sistema de classificação de Meggit-Wagner, representado na tabela 1.1, sendo este sistema utilizado nos serviços de saúde para a classificação, intervenção e encaminhamento do utente diagnosticado. Contudo, apenas os casos de grau 0 não apresentam sinais visíveis da presença de úlcera, ou sejam, são casos considerados como situações de risco de inflamação. Por consequente, na maioria das situações, a técnica de avaliação do risco de ulceração utilizada é através de exames físicos que comprovem a perda de sensibilidade[7]. Contudo, este método de avaliação não abrange a totalidade dos casos de pré-ulceração uma vez que a perda da sensibilidade depende da natureza da úlcera. Assim sendo, atualmente fazem falta, na assistência médica, métodos não evasivos e eficazes para a deteção precoce.

Tabela 1.1: Classificação de Úlcera de Meggitt-Wagner. [7]

Grau	Características da ferida
0	Lesões pré-ulceração, úlceras cicatrizadas, presença de deformidade óssea.
1	Úlcera superficial sem envolvimento de tecido subcutâneo.
2	Penetração através de tecido subcutâneo; pode expor osso, tendão, ligamento ou cápsula de articulação.
3	Osteíte, abscesso ou osteomielite.
4	Gangrena do dedo.
5	Gangrena do pé.

## 1.2 Motivação

A alteração da temperatura pode ser considerada um sintoma da presença de várias patologias no ser humano e, por este motivo, a monitorização da temperatura em meios clínicos é considerada um indicador de diferentes doenças. A termografia médica é um método que possibilita a monitorização pretendida porque permite analisar a distribuição da temperatura presente na superfície da pele no momento da captura da imagem. Por se tratar de um método não invasivo, não ionizante e preciso, possui um elevado potencial de uso para as práticas clínicas tanto em diagnóstico como em tratamento ou monitorização. Desta forma a termografia é um método complementar e não um substituto dos métodos atualmente existentes. Algumas destas utilizações encontram-se referidas nos artigos de K. Ammer[13][14] não existindo ainda, contudo, um sistema normalizado, prático e adaptado que simplifique o uso desta técnica.

Neste sentido, a monitorização da temperatura torna-se numa alternativa viável para a deteção precoce da patologia do pé diabético uma vez que nem todos os casos de pré-ulceração levam à perda de sensibilidade e a alterações no fluxo sanguíneo. Por este motivo, é recomendado o rastreio periódico, contudo, na atualidade, não existe uma ferramenta objetiva de rastreio através de processamento e captura de imagens térmicas[15].

Apesar da existência de uma relevante recolha previamente efetuada, em projetos da FEUP durante os últimos 3 anos, que permite uma boa caracterização do problema e comprova a possibilidade de utilização de termografia no diagnóstico do pé diabético, é necessário criar uma ferramenta mais avançada de análise de dados para permitir o seu uso corrente. Neste sentido, pretende-se adaptar técnicas utilizadas em análise inteligente de dados (Data-Mining), mais especificamente, métodos de classificação de dados provenientes da área de aprendizagem automática (Machine Learning). Com esta adaptação, pretende-se que seja possível identificar, através da classificação efetuada pelos métodos aplicados, a existência de úlceras nas imagens térmicas.

## 1.3 Finalidade

Com o trabalho desenvolvido pretende-se que seja possível identificar, através da classificação efetuada pelos métodos adaptados e aplicados, a existência de úlceras nas imagens térmicas. Desta forma, o resultado final possibilita uma ferramenta informática que no futuro poderá ser utilizada para apoiar o rastreio e seguimento de pacientes em risco de desenvolver pé diabético em Portugal. Para que esta finalidade seja alcançada é necessário assegurar duas características fundamentais: eficácia e simplicidade em termos de utilização.

Por um lado espera-se que a ferramenta seja de simples utilização para que possa ser adotada tanto pelos meios complementares de diagnóstico do Sistema Nacional de Saúde (SNS) como por outros meios de assistência na doença disponíveis em Portugal. Caso contrário será uma ferramenta obsoleta.

Por outro lado, para que o trabalho desenvolvido possa ser utilizado no futuro é necessário assegurar a sua complexidade no sentido de ser eficaz em qualquer tipo de dados para que os

resultados sejam fiáveis. Caso contrário, a alternativa de identificação prematura do pé diabético desenvolvida não servirá de garantia se a probabilidade de apresentar resultados incorretos for alta.

## 1.4 Objetivos

Para que a finalidade proposta seja cumprida, é necessário definir quais os objectivo a alcançar com esta dissertação:

1. Estudo dos formatos proprietários de imagens térmicas mais comuns e disponíveis.
2. Definir um conjunto de dados para armazenar as imagens recolhidas de pé diabético.
3. Desenvolver uma ferramenta de análise avançada com métodos de processamento de imagem.
4. Armazenar, numa base de dados, as imagens recolhidas em projetos anteriores da FEUP.
5. Desenvolver e avaliar a *performance* dos classificadores de dados correlacionando-os com a classificação previamente determinada.

## 1.5 Estrutura da dissertação

Para além da introdução, esta dissertação contém mais 8 capítulos e vários anexos. Os tópicos seguintes indicam o tema do conteúdo de cada capítulo:

- No capítulo 2, é descrito o estado da arte e são apresentados trabalhos relacionados com a termografia.
- No capítulo 3, é apresentada uma revisão do uso de ferramentas de classificação em aplicações clínicas com a termografia.
- No capítulo 4, encontra-se as especificações genéricas do projeto desenvolvido, nomeadamente, a arquitetura e os requisitos do sistema.
- No capítulo 5 é explicada a metodologia adotada na parte da análise de imagens térmicas deste projeto.
- O capítulo 6 remete para um esclarecimento da forma como a base de dados foi construída e da metodologia adotada para a aplicação da classificação.
- No capítulo 7 são apresentados os resultados obtidos ao longo do desenvolvimento desta dissertação.
- No capítulo 8 é realizada uma análise dos resultados e é apresentada uma resposta a cada um dos objetivos propostos.



- O capítulo 9 é a parte mais conclusiva deste documento que inclui sugestões de trabalho futuro.



## Capítulo 2

# Estado da arte

Este capítulo pretende introduzir os estudos, artigos e as investigações mais teóricas que foram efetuadas até ao momento por diferentes entidades e que estão relacionados com o tema desta dissertação.

### 2.1 Fundamentos da termografia

#### 2.1.1 Conceitos fundamentais de energia Térmica

##### 2.1.1.1 Espectro eletromagnético

Toda a energia existente pode ser expressa no espectro eletromagnético em função das frequências e comprimentos de onda. Numa geral representação do espectro eletromagnético, este encontra-se dividido por diferentes regiões denominadas por bandas do espectro.

As diferentes regiões podem ser distinguidas por métodos utilizados para produzir e detetar a radiação. Não há diferença fundamental entre a radiação nas diferentes bandas do espectro eletromagnético. Por este motivo, são aplicadas as mesmas regras e fórmulas de cálculo em qualquer uma das bandas sendo que o que varia em cada uma delas é o comprimento de onda e respetiva frequência.

Contudo, com as experiências executadas por Herschel, concluiu-se que a energia térmica é diferente para cada uma das cores da parte da luz visível sendo que é crescente no sentido do violeta para o vermelho. Outra conclusão foi a existência de energia térmica na região dos infravermelhos, localizada à direita do espectro visível. Na figura 2.1 podem ser consultadas as frequências que pertencem à energia libertada sob a forma de radiação térmica e também as partes em que se pode decompor a energia infravermelha [16].

##### 2.1.1.2 Temperatura e radiação

A Temperatura é uma grandeza fundamental inserida no sistema internacional de unidades (SI) que apresenta medições relativas a um dado sistema. Esta medida da energia cinética avalia o nível de agitação das moléculas que constituem um corpo na medida em que, quanto maior for




Figura 2.1: Espectro eletromagnético relacionado com a energia térmica

o movimento das partículas, maior será a temperatura apresentada e, portanto, mais quente será o corpo. A existência de corpos num dado sistema com valores de temperatura distintos gera a necessidade de transmissão de energia porque todos os sistemas procuram obter um equilíbrio térmico.

As ondas eletromagnéticas são o resultado do fluxo térmico, ou seja, da transmissão da radiação térmica de um corpo mais quente para um corpo mais frio. Uma vez que o estado de equilíbrio térmico nunca é alcançado, todos os corpos estão em constante transmissão de radiação térmica.

A forma de radiação que ocorre numa superfície depende do modo como ocorre a incidência da mesma. As formas de representar a radiação que incide numa superfície variam consoante a origem, trajeto e efeito produzido pela radiação. Algumas representações conhecidas são: transmissão, reflexão, refração, difusão, absorção e emissão.

### 2.1.1.3 Emissividade e corpo negro

Entende-se por emissão a radiação que é emitida pela superfície de um corpo para o seu exterior. Emissividade é uma medida para a capacidade que um corpo possui de emitir energia a partir do seu interior, comparativamente com a emissividade de um corpo negro. Esta taxa varia entre 0 a 1, onde 0 é atribuído a um corpo que reflete toda a radiação (como por exemplo um espelho) e 1 significa que absorve toda a energia tratando-se portanto de um corpo negro. Relativamente à pele do corpo humano é internacionalmente aceite que o valor da emissividade seja 0.98.

O conceito de corpo negro é atribuído a um objeto ideal que não existe na realidade. Por possuir emissividade 1, este corpo tem a capacidade de absorver toda a radiação que nele incide e emitir apenas radiação térmica numa temperatura específica, emitindo-a para todas as frequências e comprimentos de onda. Apesar de não existir fisicamente um corpo negro, existem equipamentos e mecanismos de aproximação que são utilizados na validação de resultados apresentados por câmaras termográficas.

### 2.1.1.4 Distribuição de Planck, lei de deslocamento de Wien e lei de Stefan-Boltzman

Embora o corpo negro apenas emita radiação numa dada temperatura, a frequência e o comprimento de onda relativos à temperatura especificada podem variar. Para calcular a intensidade espectral, mais concretamente, a emitância produzida por um corpo negro, utiliza-se a lei de Planck. Nesta expressão, o valor da radiação é obtido em função do comprimento de onda e da temperatura expressos na seguinte fórmula[2]:

$$E_{\lambda,b}(\lambda, T) = \frac{C_1}{\lambda^5 [\exp(\frac{C_2}{\lambda T}) - 1]} \quad (2.1)$$

Onde:

$E_{\lambda,b}$  = emitância espectral (intensidade da radiação hemisférica)  $[W/m^2 \cdot \mu m]$

$C_1 = 3.742 \times 10^8 [W \cdot \mu m^4/m^2]$

$C_2 = 1.4387 \times 10^4 [\mu m \cdot K]$

$\lambda$  = comprimento de onda da radiação  $[\mu m]$

$T$  = temperatura absoluta  $[K]$

A distribuição de Planck apresenta a quantidade de radiação emitida por um corpo negro numa representação gráfica que se pode observar na figura 2.2.




Figura 2.2: Representação da distribuição de Planck para os vários comprimentos de onda, adaptado de [2]

Derivada da lei de Planck surgiu a lei de deslocamento de Wien. Neste caso, é possível calcular o comprimento de onda ( $\lambda_{max}$ ) que corresponde à intensidade de radiação máxima para uma dada temperatura. Este valor é obtido com o cálculo da expressão 2.2.

$$\lambda_{max} = \frac{b}{T} \quad (2.2)$$

Onde:

$\lambda_{max}$  = comprimento de onda correspondente à intensidade de radiação máxima [m]

$b = 2.8977685 \times 10^{-3} \equiv$  constante de dispersão de Wien [ $m \times K$ ]

$T$  = temperatura absoluta [K]

A figura 2.3 representa a lei de deslocamento de Wien na distribuição de Planck para os vários comprimentos de onda de um corpo negro. Tal como se pode observar, o aumento da temperatura e intensidade da radiação emitida é inversamente proporcional ao valor do comprimento de onda.




Figura 2.3: Representação da lei de deslocamento de Wien

Dentro do mesmo contexto é importante ainda referir a lei de Stefan-Boltzman. Nesta lei, a energia total irradiada por um corpo negro é diretamente proporcional à quarta potência da temperatura, expressa pela expressão 2.3.

$$J = \varepsilon \times \sigma \times T^4 \quad (2.3)$$

Onde:

$J$  = energia total [ $W/m^2$ ]

$\varepsilon$  = valor da emissividade

$$\sigma = 5,669 \times 10^{-8} [W/m^2 \times K^4] \equiv \text{constante de Stefan-Boltzmann.}$$

$$T = \text{temperatura absoluta } [K]$$

Em suma, todos estes conceitos pertencentes à física térmica são importantes para esclarecer o modo como as câmaras térmicas calculam o valor da temperatura. Este cálculo é feito utilizando a quantidade de energia absorvida pelos sensores da câmara na equação 2.4.

$$T = \sqrt[4]{\frac{J}{\varepsilon \times \sigma}} \quad (2.4)$$

Onde:

$$T = \text{temperatura absoluta } [K]$$

$$J = \text{energia total } [W/m^2]$$

$$\varepsilon = \text{valor da emissividade}$$

$$\sigma = 5,669 \times 10^{-8} [W/m^2 \times K^4] \equiv \text{constante de Stefan-Boltzmann.}$$

### 2.1.2 Evolução da termografia

A temperatura à superfície da pele é um indicador físico relevante para a análise do normal funcionamento do corpo humano. Esta constatação foi inicialmente apoiada por Hipócrates, o físico grego também conhecido como pai da medicina moderna, nas suas teorias de que as doenças têm causas naturais e não acontecem por causas supersticiosas ou divinas. Para comprovar estes ideais na época, foram registados valores de temperatura utilizando banhos de lama. Com estes registos conseguia-se diferenciar as regiões mais quentes das mais frias e, com isto, era possível identificar as áreas em que haveria mais probabilidade de existirem doenças.[17] .

Mais tarde, em 1871 foi publicado o trabalho elaborado por Carl Wunderlich que caracterizou a temperatura de várias patologias e introduziu a utilização de termómetros e gráficos de temperatura em práticas clínicas[18][19].

Devido à constante evolução da medicina e da tecnologia, existem atualmente diversos métodos de captura de imagem utilizados em práticas clínicas. Cada um destes métodos tem as suas características próprias e utiliza uma banda específica do espectro eletromagnético. A figura 2.4 apresenta um resumo sobre em que medida as várias porções do espectro eletromagnético são utilizadas em diferentes práticas incluindo uma caracterização dos respetivos métodos[2].

Relativamente à termografia, esta apresenta algumas vantagens conhecidas, como por exemplo, o facto de não expor indivíduos a radiação ionizante, de ser um método não invasivo, a existência de equipamentos portáteis e o tempo de captura das imagens ser consideravelmente curto.

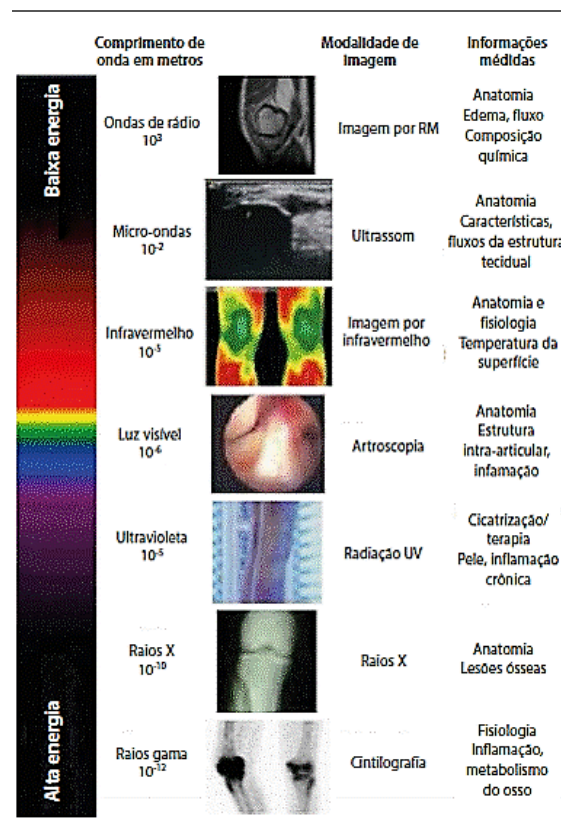


Figura 2.4: Espectro eletromagnético e sua utilização, retirado de [2]

### 2.1.3 Aquisição e recolha de termogramas

Devido ao facto de as imagens térmicas serem sensíveis às mudanças das condições ambientais, como por exemplo às alterações da humidade relativa do ar, existe a necessidade de se criar um protocolo com as normas necessárias para a captura de termogramas [20].

A aquisição em termografia pode ser dividida nas categorias de estática ou dinâmica, isto é, imagens com captura única ou com várias capturas ao longo do tempo a fim de estudar o comportamento verificado como resposta à presença de um estímulo, que pode ser térmico, mecânico ou químico. Outra divisão possível acontece com a repetição da captura que pode ser única, acompanhada ou sequencial.

As câmaras térmicas são equipamentos que nos últimos anos têm evoluído positivamente permitindo cada vez mais qualidade e veracidade nas imagens capturadas.

A FLIR® Systems[21] é uma companhia pioneira na área da captura de imagens térmicas devido ao seu desenvolvimento tecnológico e disponibilização de produtos como câmaras térmicas cada vez com mais definição e melhorias nas características. Este empenho e disponibilidade torna esta empresa líder de mercado nesta área.



### 2.1.4 Termografia aplicada ao pé diabético

No sentido de especificar o uso da termografia na problemática do pé diabético foi recolhida e analisada informação relevante e disponível até à data que relacione a imagem térmica com a avaliação de úlceras em pé diabético. Os assuntos aqui descritos foram baseados na bibliografia consultada e apresentada de seguida.

Primeiramente, no ano de 2007, foi publicado um artigo[22] realizado com o intuito de avaliar se a monitorização de temperatura a partir do lar é um método efetivo no rastreio do pé diabético. Neste sentido, foi testada a hipótese de que a auto-monitorização poderia reduzir a taxa de ulceração no pé contribuindo, por isso, para a melhoria da qualidade de vida do doente. Ou seja, esta monitorização tinha como objetivo avaliar o risco de incidência de úlceras em pés de pacientes diabéticos considerados de alto risco. Foram criados dois grupos de pacientes para a avaliação: um com os pacientes com histórico de úlceras ou amputações e outro grupo com os pacientes de perda sensorial ou deformidades estruturais no pé. Como resultado, esse mesmo estudo apresenta gradientes de alta temperatura entre os pés que podem prever o início do aparecimento de úlceras e a auto-monitorização pode reduzir esse mesmo risco.

Um artigo mais recente[23] contempla uma revisão dos estudos que relacionam a temperatura na superfície do pé com a tomografia térmica do pé diabético. Neste estudo, são apresentados o potencial e os benefícios da utilização da termografia infravermelha em problemas do pé diabético e ainda são apresentados os diferentes métodos de análise para os termogramas bem como as vantagens e as desvantagens de cada um. Dos métodos de análise apresentados (temperatura independente dos membros, temperatura assimétrica, distribuição da temperatura e, por último, análise da temperatura na presença de um estímulo de stress externo) é indicado que as análises mais utilizadas sejam a assimétrica e a de stress externo e, noutro extremo, a menos utilizada é a distribuição de temperaturas. Com a análise da temperatura independente dos membros obtêm-se intervalos de temperatura representativos entre diferentes grupos de estudo, contudo, não é possível detetar áreas específicas relacionadas com o risco elevado de presença de úlcera. Na análise da temperatura assimétrica é realizada uma comparação entre a temperatura de um ponto num pé com a temperatura do ponto contralateral respetivo presente no outro pé. Com esta comparação é possível detetar áreas de risco elevado de presença de úlceras e por isso este método tem apresentado bons resultados. Contudo, apresenta também limitações, como por exemplo o facto não funciona quando o paciente apresenta complicações similares nos dois membros ou nos casos em que o paciente apresente amputações e por isso não se pode calcular o valor da diferença de temperatura para os pontos em análise. A análise da distribuição de temperatura tem como maior vantagem não utilizar comparações e, portanto, não apresenta as mesmas dificuldades que o método anterior. Apesar disto, é um método pouco utilizado e por isso não existe até à data um padrão para representar a distribuição de temperatura num pé normal embora tenham sido reportados padrões irregulares na distribuição de temperatura de pés diabéticos, o que dificulta a classificação destas distribuições. Numa análise de stress externo é aplicado um estímulo externo no paciente (por exemplo: imersão do membro em água fria) e é analisado o comportamento da temperatura plan-

tar ao estímulo aplicado. Um dos principais inconvenientes desta análise é o desconforto que pode causar nos pacientes.

No ano de 2015, outro artigo de revisão[24] descreve a abordagem adotada por uma investigação em curso. Essa investigação pretende aliar a detecção precoce de complicações no pé diabético com componentes complementadas por um ecossistema computacional. De uma forma mais detalhada, o projeto inclui a junção de equipamento físico com uma aplicação alojada numa plataforma web e a metodologia pode ser explicada em cinco partes. No início, é capturada uma imagem térmica plantar de um paciente através de um *scanner* térmico. De seguida, o técnico profissional responsável pela captação confirma se a imagem foi corretamente capturada e a seguir envia a imagem (*upload*) para a aplicação *web* desenvolvida. Na terceira parte deste projeto a imagem é processada pela aplicação. Neste processamento, a imagem é segmentada de forma a que resulte em dois segmentos (um segmento para cada pé). Na quarta parte, cada segmento é dividido de forma a obterem-se as Regiões de interesse (ROI - *Regions Of Interest*) e é avaliado o risco da presença de úlceras em cada região de acordo com as assimetrias detetadas nos valores da temperatura. Por fim, tanto a imagem inicialmente enviada para a aplicação como os dados resultantes da avaliação do risco são encapsulados para o formato DICOM (*Digital Imaging and Communications in Medicine*) que é um formato *standard* para imagens médicas. Em suma, esta solução em desenvolvimento permite registar imagens termográficas e monitorizar a evolução de casos clínicos ou identificar atempadamente o desenvolvimento de úlceras.

Uma publicação do ano de 2015[25] apresenta a abordagem de uma detecção sustentada por um sistema inteligente de telemedicina descrito como viável e rentável. Após a aquisição de imagens térmicas procedeu-se à segmentação das áreas correspondentes à planta do pé. Devido ao facto de existir uma pequena diferença de temperatura entre algumas partes do pé importantes na segmentação e a temperatura ambiente, foi difícil conseguir um bom resultado da segmentação e por isso foram adotadas várias abordagens nesta etapa. O melhor resultado foi obtido quando se segmentaram imagens RGB e se combinaram esse resultados com as capturas térmicas. Depois da segmentação estar concluída, a etapa seguinte tinha o objetivo de detetar zonas de risco de presença de complicações associadas à patologia do pé diabético. Foi realizada uma análise assimétrica com um critério de identificação de 2.2°C. Os resultados apresentados foram satisfatórios e demonstram como a abordagem é promissora embora sejam também apresentadas algumas limitações como o caso em que é impossível realizar análise assimétrica em casos de amputamentos e em casos de existir complicações simétricas nos dois pés. Outra limitação encontrada foi a inexistência de um padrão ideal *standard* para a segmentação e registo do valor de temperatura, sendo complicado avaliar os resultados objetivamente.

Num trabalho de detecção e análise da hipertermia do pé diabético, os autores de um artigo [26] publicado em 2016, criaram um programa que, através de capturas térmicas, produz imagens com a leitura do valor da diferença de temperatura média absoluta de sete regiões entre o pé esquerdo e o pé direito (análise assimétrica). A metodologia adotada pode ser explicada em duas etapas: segmentação e avaliação. Na segmentação procurou-se seleccionar apenas as partes da imagem pertencentes às zonas do pé e de seguida dividiram-se essas partes de forma a obterem

as ROIs pretendidas. Na avaliação, as 85 imagens de pés diabéticos recolhidas foram divididas e classificadas consoante o grau de risco da presença de úlcera: alto, médio ou baixo. Como resultados genéricos, pé diabéticos com o valor da diferença de temperatura média superior a 2.2°C foram apontados como pacientes que carecem de atenção reforçada por parte dos médicos porque existe um grande potencial de desenvolver complicações como úlceras ou infeções. Como limitação, este estudo apresenta a necessidade de uma câmara térmica para a recolha de imagens a fim de facilitar a segmentação e, por consequência, a leitura dos valores de temperatura.

## 2.2 Formatos de imagens térmicas

### 2.2.1 Formatos dos Ficheiros

As câmaras usadas para a captação das imagens infravermelhas (*IR - infrared*) são do fornecedor FLIR[21], mais concretamente, tratam-se das câmaras FLIR ONE[27], FLIR A325sc e FLIR E60sc.

Destas câmaras consegue-se extrair imagens de diferentes formatos de ficheiro, sendo esses tipos o .IMG, o .SEQ e o .JPEG radiométrico. Para cada formato de imagem a informação que se pretende extrair encontra-se estruturada de formas diferentes. Neste sentido, é necessário ter em conta o formato de cada um dos diferentes tipos.

### 2.2.2 Extensões de metadados

Metadados são informações sobre as características presentes no ficheiro e nos dados nele contidos. Estes metadados são divididos por extensões e subdivididos por itens (*tags*). Neste sentido, uma *tag* é a unidade básica de metadado.

Para além de existirem diferentes formatos de imagem, existem também várias extensões que disponibilizam metadados contidos nos ficheiros das imagens térmicas. Das diferentes extensões existentes será dado mais destaque à extensão .FFF (*Flir System thermal image File Format*) e à .FPF (*Flir Public image Format*). Embora o conteúdo presente nestas extensões seja semelhante existem algumas diferenças que não podem ser desprezadas.

No anexo A encontram-se algumas tabelas informativas sobre quais os dados provenientes das extensões referidas. Nomeadamente, as tabelas A.1 e A.2 mostram algumas das informações que se podem retirar a partir da extensão .FFF. A tabela A.3 mostra as informações que se pode retirar da extensão .FPF.

### 2.2.3 Aplicação ExifTool

Com o auxílio da ferramenta Exiftool[28], é possível decodificar as informações *metadata* de vários tipos de ficheiros. Exiftool é uma aplicação que corre na linha de comandos de vários sistemas operativos e que possibilita a leitura, escrita e edição de informação do tipo *metadata*.

Depois de utilizar esta ferramenta em alguns ficheiros do tipo .img obtiveram-se os valores para alguns dados que serão necessários para o processamento correto das imagens. Estes dados

estão apresentados mais concretamente na tabela B.1 para as imagens do tipo .img e na tabela B.2 para as do tipo .jpg.

### 2.2.4 Fórmula de cálculo de temperatura em imagens térmicas

Tal como se pode verificar pelos resultados do *Exiftool*, das imagens recolhidas, conseguem-se recolher valores para cinco constantes de *Planck*. Estes dados são cruciais para o cálculo correto do valor de temperatura.

A fórmula correta para a cálculo do valor da temperatura de um objecto capturado depende do valor radiométrico e das cinco constantes de Planck[29] como se pode observar na expressão 2.5:

$$T = \frac{B}{\ln\left(\frac{R1}{R2 \cdot (S+O)} + F\right)} \quad (2.5)$$

Onde:

$T$  = temperatura do objecto [ $K$ ]

$S$  = valor radiométrico (16 Bit)

$R1$  = constante Planck  $R1$

$R2$  = constante Planck  $R2$

$B$  = constante Planck  $B$  , valor no intervalo [1300, 1600]

$F$  = constante Planck  $F$  , valor no intervalo [0.5, 2]

$O$  = constante Planck  $O$  (*offset*) , valor negativo

## 2.3 Técnicas de processamento de imagem

### 2.3.1 Pré-processamento

O pré-processamento de imagem é uma técnica útil para uma melhor leitura e análise de dados importantes em imagens térmicas. Dois fatores a ter em conta são, por exemplo, o contraste com o fundo da imagem (*background*) e a presença de ruído indesejado.

Numa imagem térmica, a existência considerável de ruído pode afetar a extração do objeto de interesse e dificultar os valores reais da medição de fraco contraste entre o alvo e o *background* pode afetar a extração do objeto de interesse e aumentar o tempo perdido na sua análise. Conforme o que foi publicado pelo artigo de Bajwa et al publicado em 2010 [30], os operadores baseados em probabilidade produzem o melhor resultado, especialmente após pré-processamento com um filtro de remoção de ruído.

Quanto ao fator de presença de ruído, outro artigo[31], compara várias técnicas de remoção de ruído com o intuito de classificar e apurar qual melhor se adapta sem causar uma leitura errada dos valores de temperatura. Como resultado final os que melhor se adaptam são os filtros *Median*,

*Mean* e *Wiener*, contudo, é sugerido ainda que a filtragem de ruído só deve ser aplicada quando especificamente necessário.

Os filtros de média (*mean*) são do tipo de filtros de suavização lineares, ou seja, processam a imagem original com uma mascara convolucional a fim de eliminar o ruído existente. Por outro lado, os filtros de mediana (*median*) e *Wiener* são filtros não-lineares, ou seja, o resultado não é obtido através da aplicação de uma função global linear na imagem original mas sim através de funções locais. No caso do filtro Wiener, com a sua utilização pretende-se que o resultado apresente uma diferença mínima relativamente à imagem original.

### 2.3.2 Segmentação

No processamento de uma dada imagem, vulgarmente é necessário segmentar certas regiões nela contidas. Para se atingir este fim existem métodos de segmentação que se baseiam em propriedades dos pixels presentes na imagem. Por um lado existem métodos de segmentação que se baseiam em propriedades de semelhança como o *thresholding* (segmentação baseada em histograma), *clustering* (segmentação baseada em agrupamento) e ainda segmentação baseada em regiões. Por outro lado a segmentação pode ser baseada em propriedades como a diferença ou descontinuidade dando origem a métodos de segmentação baseada em contornos e segmentação de pontos, linhas, orlas e cantos[3].

O método de binarização *thresholding* é o mais simples de se implementar. Consiste na seleção de um valor de limiar a partir do histograma da imagem, ou seja, a partir da representação da distribuição de intensidade que é medida em cada ponto da imagem, sendo que, no eixo das abcissas encontra-se a escala das intensidades possíveis (de 0 a 255) e no eixo das ordenadas a quantidade de pixels. Ao selecionar-se um determinado valor de intensidade para o limiar, o resultado de uma imagem binarizada apresenta apenas duas classes ou intensidade possíveis: 0 ou 255 que corresponde, respetivamente, à classe cor preta ou classe cor branca. Para esta conversão é usada apenas uma condição: se determinado pixel tem o valor de intensidade igual ou abaixo do valor de limiar definido, este pixel passa a ser preto. Caso contrário, o pixel passa a ser branco. Este método de segmentação é o mais adequado quando o histograma é bimodal. Para que a escolha do limiar permita um resultado com classes bem segmentadas, ou seja, foi obtida a melhor separação possível entre as classes, existe o método Otsu em que o valor do limiar é escolhido de forma a maximizar a variância inter-classe[32].

Um histograma bimodal é um histograma com duas modas, ou seja, na representação gráfica é possível identificar dois “picos” distanciados. Na figura 2.5 encontra-se um exemplo deste tipo de histogramas.

Para histogramas que não sejam bimodais existem algumas dificuldades na aplicação do *thresholding* devido ao acréscimo de dificuldade da escolha do limiar ótimo. Contudo, esta pode ser ultrapassada se for previamente definido um método para o cálculo do limiar que funcione para o que se pretendia como por exemplo: selecionar apenas determinados pixels da imagem para a determinação do limiar.




Figura 2.5: Exemplo de um histograma bimodal [3]

## 2.4 Regiões de interesse para a detecção do pé diabético

Relativamente à problemática do pé diabético, tal como foi esclarecido em 1.1, a existência de pontos de calor elevado (*hotspots*) no pé podem indicar áreas de inflamação antes do aparecimento de sinais visuais. Neste sentido, é necessário um estudo sobre quais as regiões de interesse (*Regions Of Interest - ROI*) existentes na vista plantar do pé necessárias para a detecção dos *hotspots*. De seguida encontra-se uma pequena revisão sobre as ROIs definidas em algumas publicações relativas ao tema.




Figura 2.6: Regiões de Interesse utilizadas[4]

O artigo de Audrey[4] relativo a um novo sistema de câmara térmica ajustado, desenvolvido para os pés em risco térmico, descreve o padrão térmico e simétrico da distribuição de temperaturas obtidas em 103 pares de pés termicamente saudáveis. Em análise são apresentadas quais as ROI que foram utilizadas e, como justificação, são descritas as investigações que motivaram o uso destas regiões. A figura 2.6 foi retirada do artigo em questão e pretende mostrar a localização das 33 regiões de interesse de cada pé que foram utilizadas.

No já referido livro de termografia publicado em 2016[2], é apresentada uma caracterização de

úlceras do pé diabético com imagem térmica. No procedimento de captura, é indicada a necessidade da recolha de imagens térmicas ser realizada numa sala com a temperatura controlada, e os pés estarem despidos e livres de qualquer ornamento metálico ou outro objecto que possa interferir com a captura. Como regiões de interesse foram escolhidas as áreas onde existe maior incidência de úlceras diabéticas, estas regiões são apresentadas na figura 2.7.



Figura 2.7: Regiões de Interesse utilizadas para a caracterização [2]




Figura 2.8: Distribuição dos tipos de úlceras pelas regiões de interesse [2]

Como justificação das ROIs indicadas, é apresentado um gráfico de distribuição dos tipos de úlceras diabéticas pelas regiões de interesse. Esta distribuição foi obtida atendendo aos valores de simetria térmica existente entre as várias imagens capturadas, dos vários tipos de úlceras, utilizadas para a caracterização descrita. O gráfico da distribuição encontra-se na figura 2.8.

## 2.5 Sistemas de gestão de base de dados

Com o intuito de averiguar quais os sistemas de gestão de base de dados existentes e qual o melhor se adapta ao pretendido nesta dissertação foram consultados alguns *rankings* atualizados sobre DBMS (*DataBase Management Systems*). Na informação pesquisada[33] é possível encontrar *rankings* de acordo com a popularidade de vários DBMS e é também apresentado o método utilizado para o cálculo da pontuação utilizado para o ranking efetuado. A tabela 2.1 mostra os cinco primeiros lugares do *ranking* consultado.

Tabela 2.1: *Ranking* adaptado da atualização de Junho de 2017[8]

Posição	DBMS	Pontuação
1	Oracle	1351.76
2	MySQL	1345.31
3	Microsoft SQL Server	1198.97
4	PostgreSQL	368.54
5	MongoDB	335.54

De seguida, na tabela 2.2 são apresentadas especificações mais técnicas de cada DBMS da tabela anterior.

Tabela 2.2: Detalhes de cada DBMS

	Oracle	MySQL	Microsoft SQL Server	PostgreSQL	MongoDB
Modelo da base de dados	orientada a objectos	orientada a objectos	orientada a objectos	orientada a objectos	orientada a documentos
Desenvolvedor	Oracle	Oracle	Microsoft	PostgreSQL Global Development Group	MongoDB, Inc
Licença	<i>commercial</i>	<i>open source</i>	<i>commercial</i>	<i>open source</i>	<i>open source</i>
SQL	Sim	Sim	Sim	Sim	Não

## 2.6 Sumário

Todos os conceitos relativos à energia térmica referidos são necessários para assegurar e validar a correta leitura da temperatura através de uma câmara térmica. Contudo, para assegurar a correta leitura do valor de temperatura a partir de uma câmara térmica, é necessário ter em conta quais os dados possíveis de extrair dos ficheiros de formatos proprietários e de que forma se calcula a temperatura com a informação disponível.

As diversas aplicações realizadas até à atualidade da termografia em práticas clínicas asseguram a sua utilidade e provam que a termografia poderá ser utilizada como um meio complementar para o diagnóstico sem substituir ou interferir com nenhuma outra técnica utilizada. Por outro lado



é importante também concluir que para a termografia seja bem analisada é necessário garantir condições ideais para que a captura seja bem sucedida e métodos de segmentação que não eliminem partes da imagem essenciais para a análise pretendida.

Em detalhe, para a problemática envolvente na patologia do pé diabético, foi necessária uma revisão sobre as ROIs definidas noutras publicações. Desta forma fica fundamentado a escolha das ROIs que serão utilizadas no sistema desta dissertação, uma vez que, são estas as ROIs onde há maior propensão de ocorrerem úlceras do pé diabético.

A fim de implementar uma base de dados útil e que preencha os requisitos determinados para esta dissertação foi necessário uma pesquisa sobre os DBMS existentes no mercado e quais as suas especificações.

Sendo estas conclusões genéricas importantes para o tema desta dissertação, falta ainda uma revisão e explicação sobre a utilização de classificadores. Desta forma, o capítulo que se segue preenche esta lacuna.



## Capítulo 3

# Revisão do uso de classificadores em termografia

Em simultâneo com o desenvolvimento desta dissertação foi elaborado um capítulo inserido no livro “*Classification in BioApps: Automation of Decision Making*”. Esse capítulo, intitulado “*Classification and decision making with medical infrared thermal imaging*”, foi aceite para publicação pela editora Springer.

O presente capítulo desta dissertação pretende apresentar de forma sumariada a revisão efetuada para o capítulo da publicação que é também importante para o desenvolvimento deste projeto, mais concretamente, encontram-se revistos os métodos: Redes Neurais, Redes Baysianas, *Support Vector Machine* e o Algoritmo *K-Nearest Neighbor*.

Para que seja possível a realização de uma análise crítica é necessária ainda uma revisão sobre a avaliação da classificação de dados. Esta análise torna-se fundamental para o reconhecimento de problemas no pé diabético.

Por último, existe uma ferramenta de livre utilização intitulada “WEKA” que permite a aplicação de classificadores em conjuntos de dados e portanto é uma ferramenta muito útil e pode ser utilizada para avaliar a qualidade da aplicação de vários tipos de classificadores nesses conjuntos de dados.

### 3.1 Método para a avaliação de um classificador

Primeiramente, antes de perceber o modo de funcionamento de diversos classificadores, é necessário perceber quais são os resultados possíveis de uma classificação.

O resultado da aplicação dos diversos classificadores no problema do pé diabético pode ser considerado como uma resposta binária em que existem quatro casos possíveis: verdadeiro positivo (VP), verdadeiro negativo (VN), falso positivo (FP) e falso negativo (FN). Estes quatro casos podem ser divididos como resultados corretos ou incorretos. Nos primeiros dois casos, o resultado obtido foi o correto, sendo que no caso VP foi detectado corretamente o problema num pé diabético enquanto que no caso VN não foi detectado o problema num pé saudável. Por outro lado, os

outros dois resultados são incorretos já que no caso FP foi detetado o problema num pé saudável e no último caso, FN, não foi possível detectar o problema num pé infetado.

Para além desta nomenclatura, interessa ainda definir alguns métodos necessários para avaliar a qualidade nos resultados de uma classificação.

### 3.1.1 Métricas para a *performance*

No sentido de avaliar a *performance* de um classificador, existem quatro métricas importantes: exatidão, precisão, sensibilidade e especificidade. Para cada uma destas componentes existe uma fórmula de cálculo em que o valor percentual para cada componente depende da quantidade obtida de cada tipo de resposta da classificação. As expressões a seguir apresentadas mostram a fórmula de calcular cada uma das componentes.

$$\text{Exatidão} = \frac{VP + VN}{VP + VN + FP + FN} \quad (3.1)$$

$$\text{Precisão (de valores positivos)} = \frac{VP}{VP + FP} \quad (3.2)$$

$$\text{Precisão (de valores negativos)} = \frac{VN}{VN + FN} \quad (3.3)$$

$$\text{Sensibilidade} = \frac{VP}{VP + FN} \quad (3.4)$$

$$\text{Especificidade} = \frac{VN}{VP + FN} \quad (3.5)$$

### 3.1.2 *Receiver operating characteristic*(ROC)

O conceito de curva de característica de operação do receptor (curva ROC) é uma representação gráfica no qual é possível analisar o desempenho do classificador. Neste gráfico é representado no eixo das ordenadas a taxa de verdadeiros positivos (sensibilidade) e no eixo das abcissas a taxa de falsos positivos (100-especificidade). Deste modo, cada ponto da curva ROC apresenta os valores do par sensibilidade/especificidade correspondentes ao limiar de classificação desse ponto. A área por baixo da curva ROC (AUC - *Area Under the ROC Curve*) serve como medida do quão bem um parâmetro é distinguido entre dois grupos de classificação.

Na figura 3.1 está indicado, pela linha a vermelho, um exemplo de uma curva ROC.

## 3.2 Redes Neurais

### 3.2.1 Definição

De um modo genérico, o conceito de redes neurais artificiais (*Artificial Neural Networks* - ANNs) pertence à família de modelos computacionais aplicados em inteligência artificial. Na prá-




Figura 3.1: Exemplo de uma curva ROC

tica, traduz-se num sistema composto por “neurónios” interligados capazes de trocar mensagens entre eles[34]. Este sistema pode ser composto por uma única camada de conexões ou por múltiplas camadas permitindo a existência de um maior número de entradas para o sistema. Sendo que, a classificação por ANN é um método recorrente quando se pretende aplicar um classificador em termografia médica, na maioria das aplicações revistas são utilizadas pelo menos 3 camadas: entrada (*input layer*), saída (*output layer*) e transparente (*hidden layer*). Na figura 3.2 está apresentada um exemplo de uma rede com 3 camadas.




Figura 3.2: Arquitetura de uma rede ANN criada[5]

Por outro lado, uma rede neuronal pode ser interpretada como um modelo estatístico bastante parametrizado[35]. Esta característica torna este modelo muito flexível, ou seja, a existência de pequenas irregularidades nos parâmetros das funções não causa uma impossibilidade na reprodu-

ção do modelo. Deste modo, todos os parâmetros apresentados são modelados, contudo, este facto apresenta um perigo: o *overfitting*. Este problema ocorre quando o modelo estatístico calculado está demasiado ajustado à sua amostra, ou seja, ao conjunto de dados que o originou.

Na figura 3.3 são apresentados dois modelos de previsão: um modelo demasiado ajustado representado pela linha azul e outro mais regular a vermelho. O problema do modelo azul é que, ao serem alterados os dados da amostra o número de irregularidades que podem ocorrer será maior do que quando aplicado o modelo mais regular. Por isso, o modelo representado a preto acaba por ser mais adaptativo à realidade do que o modelo por *overfitting*. Para colmatar este problema foram adotadas estratégias que permitiram desenvolver classes de modelos de previsão mais funcionais.




Figura 3.3: Sistema de Previsão

O elemento básico para a construção de uma rede neuronal artificial trata-se de um elemento de processamento. A existência de algoritmos de construção com diferentes combinações nos elementos de processamento leva a uma grande diversidade de capacidades computacionais para as redes neuronais.

O desenvolvimento de uma rede neuronal pode ser subdividido em duas etapas: construção e ativação. Como forma de medida, para a força na ligação existente entre camadas, é definido um peso durante a fase de construção. Esta fase remete para o período de aprendizagem em que é dado à rede os dados iniciais e as soluções respetivas para que consiga construir um modelo de análise para novas representações. Os resultados desta etapa são soluções numéricas para o problema proposto. Existem três tipos de aprendizagem: supervisionada, não supervisionada e híbrida. Na fase de ativação, a aprendizagem automática está concluída e a rede está preparada para receber novos dados, analisá-los e apresentar os seus resultados.

Como exemplo de um algoritmo de construção aplicados nas redes neuronais existe o algoritmo *backpropagation* (BP) também designado como (generalized delta rule), que é um *iterative gradient algorithm* com o objetivo de minimizar o erro *mean square* que existe entre o resultado atual obtido e o expetável. Com o uso deste algoritmo, o peso associado em cada camada transparente pode ser ajustado, sendo deste modo possível a aprendizagem da rede. Este género de

sistema é fácil de ser construído e bastante usado em reconhecimento de padrões e em problemas de classificação de imagens, tal como se encontra explicado na próxima secção.

Uma ANN construída a partir de um algoritmo BP significa que a aprendizagem automática supervisionada foi realizada a partir de *feedforward* entre multi-camadass. Aprendizagem por *feedforward* significa que os elementos de processamento são propagados pela rede desde a camada de saída até à camada de entrada sem haver interconexão entre os elementos de processamento na mesma camada. As saídas são criadas do seguinte modo: é dado a cada elemento de processamento um peso ajustado à sua carga, a soma dos pesos de todos os elementos é calculada sendo este valor total transformado no resultado da saída por uma função de ativação.

O padrão de ativação que resulta nas unidades de saída, depois da aplicação da função de ativação numa rede de feedforward, codifica a resposta da rede para as unidades de entrada da mesma. Inicialmente, define-se o peso para pequenos valores aleatórios e é aplicado na rede de forma sequencial um conjunto de entradas de construção (*training inputs*). No procedimento de aprendizagem por *backpropagation* após a propagação na rede de cada dado de entrada os pesos são ajustados de forma a que haja uma redução na diferença existente entre os valores obtidos na saída e os valores de saída que seriam os corretos. Cada iteração é denominada de ciclo de construção (*training cycle*), um processo completo de ciclos de construção é chamado de época de construção (*training epoch*) e todo este procedimento é do tipo de aprendizagem automática supervisionada. Uma rede ANN com o algoritmo BP (BP-ANN) utiliza aprendizagem automática supervisionada, ou seja, o erro nos resultados de saída é determinada e utilizado como um sinal de construção/treino (*training signal*) na medida em que é utilizado para o ajuste dos pesos na rede.

Contudo, na aprendizagem automática não supervisionada não há um ajuste de peso e tem de ser a rede a ajustar convenientemente esse valor ao usar (*environmental feedback*) menos detalhado durante a performance.

RBFN (*Radial Basis Functions Network*) é uma técnica utilizada para determinar o *training signal* utilizado para ajustar o peso definido para os neurónios numa rede neuronal. Embora o resultado de RBFN ser linear, as entradas são não-lineares o que causa uma maior capacidade de modelação mais complexa de mapas, aprendizagem, classificação e capacidade de decisão comparativamente com uma BP-ANN. Este rede é composta por 3 camadas e requer aprendizagem automática supervisionada.

### 3.2.2 Utilização na termografia

Um artigo de E.Y.-k. Ng. [36] apresenta o uso de redes neurais na identificação de cancro da mama sendo este o primeiro caso do uso de classificadores na termografia médica (*Medical Infrared Thermal Imaging* - MITI). Mais concretamente, este artigo examina a utilização de ANN para complementar a radiação de calor infravermelho da superfície do corpo com outros dados fisiológicos. Neste caso, dados fisiológicos e os termogramas de alguns pacientes foram utilizados como elementos básicos para o processamento de algoritmos de BP numa rede neuronal de quatro andares. Os resultados mostram que a ANN criada consegue memorizar e generalizar a relação

existente entre os dados de entrada e os dados de saída do sistema, sendo que os melhores resultados foram obtidos no caso em que os dados de entradas continham mais informações (dados fisiológicos e dos termogramas) sobre os pacientes. A vantagem obtida foi o reconhecimento de padrões alcançado com a ANN. Uma desvantagem foi o uso de valores numéricos para os dados de entrada porque gerou resultados pouco precisos durante a aprendizagem automática da rede. Outra desvantagem foi o tempo necessário para a aprendizagem automática da rede estar concluída contudo, ultrapassada esta fase, apenas foi necessário um ciclo para detectar uma condição específica ou identificar um estado. No total, o número de pessoas que participaram no estudo foi de 207 sendo 76 saudáveis, 98 pacientes benignos e 33 pacientes malignos. No melhor, foi obtida a percentagem de 68,97% para a sensibilidade, 80% para a especificidade e 61.94% para a exatidão.

Dois anos mais tarde surgiu outra publicação [5] com os mesmos objetivos. Contudo, neste caso, foram usadas e comparadas as técnicas *nonparametric discriminant analysis* (NDA), *linear discriminant analysis* (LDA) e *principal component analysis* (PCA) com o intuito de reduzir as variáveis utilizadas. Para as variáveis básicas foram implementadas informações dos histogramas das ROI definidas, características baseadas na matriz de co-ocorrência, no gradiente e na matriz *run-length*. Todos estes dados foram provenientes de 30 pessoas saudáveis e 30 doentes. Vários testes foram efetuados e portanto os resultados variam. No caso em que foram aplicadas apenas informações dos histogramas não foram obtidos resultados conclusivos devido à necessidade implícita da ANN em que a redução de dados causa redução da distância multidimensional entre os resultados da saída. Isto significa que a probabilidade de ocorrer erros na normalização é mais alta e consequentemente a classificação poderá ser incorreta.

Em 2008, o já referido autor pioneiro na introdução de ANN em MITI, fez nova publicação [37] na tentativa de provar a fiabilidade da utilização de ANN no diagnóstico precoce do cancro da mama. Neste caso, foram utilizados alguns métodos bio estatísticos como o modelo múltiplo de regressão linear, *radial basis function network* (RBFN) e *receiver operating characteristic* (ROC). O primeiro permite a correlação entre as variáveis e o estado atual do paciente o que por sua vez permite a correta seleção das características a serem usadas durante a fase de aprendizagem (*training epoch*) que, comparativamente com a função BP, apresenta uma época mais rápida. RBFN foi usado como função de activação para determinar o resultado da classificação e, comparativamente com a função BP. Os resultados apresentam valores de 80.95%, 100% e 70.6% para, respectivamente, a exatidão, sensibilidade e especificidade. Estes resultados têm percentagens mais elevadas do que o intervalo de exatidão (de 60% a 70%) que foi obtido pela examinação efetuada por radiologistas experientes.

No mesmo ano, o autor Papez realizou um artigo [38] com o objetivo de apresentar uma melhoria no diagnóstico de síndrome do túnel cárpico (Carpal tunnel syndrome - CTS) com a utilização de redes neuronais artificiais para analisar as imagens termográficas. No total, foram recolhidos 112 termogramas que foram divididos em vários conjuntos para serem utilizados em diferentes combinações para a fase de construção e fase de testes. Mais concretamente, os dados de entrada utilizados na construção da rede foram constituídos por características numéricas (valores



de média da temperatura) e pela classe correspondente. Os resultados da classificação apresentam uma taxa de sucesso de aproximadamente 80% sendo ainda indicada a possibilidade de o valor da taxa ser superior se a quantidade de imagens utilizadas fosse maior para ampliar as possibilidades de detecção da patologia.

Por este motivo, no ano a seguir, a mesma equipa publicou outro artigo[39], com o mesmo problema e a mesma proposta mas, desta vez, foram recolhidas 502 imagens. Contudo os resultados obtidos neste caso com a classificação não apresentaram a melhoria esperada. Por outro lado, foram identificados segmentos de imagens desnecessários uma vez que, nos testes em que estes eram descartados, a taxa de sucesso da classificação subia consideravelmente. Desta forma, os autores concluíram que a MITI não pode ser considerada uma ferramenta de detecção adequada quando é exigido um nível de diagnóstico severo.

Anos mais tarde, em 2015, no artigo de Koprowski [40], é proposto um método de análise de imagem para a avaliação da distribuição de temperatura ao longo das costas dos pacientes em que foram recolhidas as imagens. O objetivo principal seria o de detetar anomalias que causam uma postura defeituosa. Para a classificação dos parâmetros recolhidos foram usados alguns classificadores, entre os quais ANN. Os resultados obtidos mostram que para ANN com a utilização de BP, 16 neurónios na camada invisível e aprendizagem por *cross validation* obteve-se uma sensibilidade e especificidade respetivamente de 75% e 89%. Contudo este não foi o classificador com mais sucesso na avaliação. O classificador com o valor percentual de sucesso mais elevado nos mesmos parâmetros foi o SVM com 88% e 90% respetivamente.

No mesmo ano, um outro estudo[41] relaciona a utilização de uma rede ANN em imagens térmicas com o intuito de identificar pessoas em estado de embriaguez. Para se alcançar o objetivo proposto foram adotadas duas abordagens. Na primeira, recorrendo a ANN, foram examinadas as temperaturas por localização em cada uma das diferentes imagens provenientes da mesma face para todas as faces recolhidas, com isto, verificou-se que era nas imagens frontais da face onde se verificava maior alteração no comportamento térmico com o consumo de álcool. Na segunda abordagem adotada, uma rede neuronal de estrutura singular foi construída com as variáveis básicas de construção provenientes de todas as localizações da face, verificando-se uma performance altamente discriminativa quando se aplicou a dados desconhecidos. Contudo, redes neuronais mais pequenas apresentaram uma melhor performance generalizada (86% de exatidão).

Por fim, o autor Saniei apresentou no seu artigo de 2016[42], uma nova abordagem para prever uma estimativa do tamanho, profundidade e da taxa de geração de calor metabólico num tumor. Essa nova abordagem é composta por duas etapas: progressiva e inversa. Para a primeira etapa foi necessário criar um modelo de elemento finito e resolver a equação *The Pennes bio-heat* para calcular a distribuição da temperatura na superfície e em profundidade. Os valores calculados obtidos foram aplicados para a construção de uma rede neuronal dinâmica (DNN) e, a fim de assegurar a correta construção da rede, os resultados desta aplicação confirmam os valores do modelo de elemento finito. Na segunda etapa, a rede construída foi utilizada para estimar a distribuição da temperatura em profundidade a partir do perfil de temperatura à superfície. De forma a evitar que a rede criada fosse demasiado ajustada e a fim de se obter um sistema com um nível de per-

formance aceitável, os autores consideraram como crucial a escolha do número de neurónios na camada invisível e das épocas necessárias, sendo que estes valores não eram dependentes entre eles mas determinados de forma iterativa. Tendo em conta a relação existente entre as variáveis utilizadas, foram encontrados os valores de 0.84 e 0.71 para o tamanho e profundidade com o erro absoluto de 0.31cm e 0.2cm respetivamente. Em nota final é indicada a necessidade de recolha de mais imagens para melhorias no sistema.

### 3.3 Redes Bayesianas

Uma rede Bayesiana (BN - *Bayesian Network*) é um modelo de representação causal e probabilístico e pode ser entendido como um grafo orientado e acíclico. Na figura 3.4 está representado um exemplo de um grafo com as especificações referidas pelas redes Bayesianas, ou seja, os vértices e as arestas representam, respetivamente, as variáveis e as relações de dependência causal. Deste modo, fica assegurado o mapeamento entre causa e efeito através de dependências probabilísticas. Desta forma, os sistemas baseados em redes Bayesianas têm a capacidade de gerar previsões automáticas no caso de existir falta de informação nos dados existentes e, portanto, não é preciso um número elevado de elementos de construção.




Figura 3.4: Exemplo de um grafo orientado e acíclico

O algoritmo de *Naive Bayes* (NB) que tem por base o cálculo probabilístico do teorema de *Bayes* com suposições de independência entre as características. A fórmula expressa pelo teorema descrito é apresentada na equação 3.6 que significa que a probabilidade da ocorrência do evento *A* sabendo que aconteceu o evento *B* corresponde à divisão entre a probabilidade da intersecção dos eventos *A* e *B* com a probabilidade do evento *B*.

$$P(A|B) = \frac{P(A \cap B)}{P(B)} \quad (3.6)$$

Por outras palavras, o classificador de NB afirma que a presença de uma característica particular numa classe não está diretamente relacionada com a presença de outra qualquer característica [43]. Uma vantagem deste classificador é o facto de necessitar de poucos elementos de construção para que seja possível calcular os parâmetros necessários para a classificação.

Na prática existem 3 casos conhecidos de aplicações do NB em termografia para a classificação em cancro da mama. Apesar de a exatidão obtida ser mais baixa comparativamente com outros classificadores, foi obtido um valor percentual de 71.86% num estudo de 2013[44]. Em outras duas publicações [45] e [43] está indicado que os valores de exatidão obtidos com a aplicação de NB foram cerca de 3% e 11%, respetivamente, a menos do que foi obtido no caso da aplicação de SVM.

## 3.4 Support Vector Machine

### 3.4.1 Definição

O conceito de “máquina de vectores de suporte” (*Support Vector Machine - SVM*) é aplicado a um conjunto de métodos de classificação que analisam dados e reconhecem padrões. Este procedimento de aprendizagem automática construtiva é baseado no princípio de minimização do risco estrutural, ou seja, pretende minimizar os limites de erro criados pela máquina de aprendizagem automática durante a fase de construção.

De uma forma geral, um classificador SVM produz resultados lineares binários, ou seja, analisa um conjunto de dados iniciais e atribui-os a uma de duas categorias possíveis. Normalmente, este algoritmo funciona bem quando é aplicado a novos dados. Isto acontece porque os dados que foram aplicados durante a fase de construção são, de um modo geral, os mais difíceis de classificar, ou seja, implica que os métodos que optem por utilizar esta técnica tenham capacidade de superar os métodos concorrentes em muitas aplicações.

Como modelo de representação, o SVM utiliza um mapeamento de pontos no espaço, sendo que, existe no espaço de representação um hiperplano que separa as duas classes. Deste modo os pontos são distribuídos no espaço de acordo com a classe pertencente. Na figura 3.5 pode-se visualizar um exemplo.

Neste exemplo, pode-se visualizar a classificação dos dados, a definição do hiperplano e da margem de separação. Os dados iniciais foram divididos em duas classes, sendo que os dados foram representados por quadrados e círculos sendo que cada uma destas representações remete para uma classe distinta. O hiperplano criado encontra-se otimizado de modo a que a margem de separação resultante seja maximizada.

Neste sentido, um algoritmo de SVM tem como objetivo definir o hiperplano do modelo de representação e pretende maximizar a distância existente entre os pontos de classes diferentes. Para a conversão dos dados iniciais *input data* em pontos no espaço é normalmente utilizado funções do tipo *nonlinear kernel*. Deste modo, os dados convertidos são apresentados de forma mais distante do que se fossem utilizados dados não convertidos.




Figura 3.5: Exemplo da representação de um SVM.

### 3.4.2 Utilização na termografia

Em 2012, na publicação de Archarya e restantes autores[46], o objetivo foi o de avaliar a viabilidade do uso da classificação em termografia no diagnóstico do cancro da mama. Através de matrizes *run length* e *co-occurrence* foram obtidas características da textura. Após o processo de normalização pretendia-se realizar a classificação com aplicação do SVM que foi escolhido com a justificação de que tinham sido obtida boa performance em estudos anteriores de reconhecimento de padrões. Na implementação foi adotado o método (*Tree-fold stratified cross validation method*), e por isso, os dados foram divididos em 3 conjuntos. Para a fase de aprendizagem do SVM criado, foram criados e utilizados combinações de dois dos conjuntos de elementos existentes. O conjunto restante de cada combinação foi utilizado para teste. Como resultados, nesta publicação foram apresentados uma exatidão de 88.10%, sensibilidade de 85.71% e especificidade de 90.48%.

No mesmo ano, Resmini e restantes autores de uma outra publicação[45], investigaram quais as características necessárias a recolher dos termogramas para a classificação e deteção do cancro da mama. Esta investigação foi um trabalho complementar que pretendia ser uma melhoria de um trabalho anterior realizado pela mesma equipa. Neste caso, foram adicionados classificadores, técnicas de seleção e dados na base de dados existente. Como requerimento foi necessário reduzir as características extraídas e por isso foram utilizadas duas técnicas: PCA e *Information Gain Ratio* (IGR). A classificação foi aplicada para etiquetar os utilizadores com a presença ou ausência da patologia. No desenvolvimento foram criadas 3 bases de dados com informações diferentes e realizados vários testes com o auxílio da ferramenta WEKA[47]. A ferramenta WEKA encontra-se explicada na secção 3.6. No melhor dos resultados apresentados foi obtida uma exatidão de 82.35% na base de dados que apresentava maior número de informação recolhida.

Já em 2014, surgiu outra publicação de Acharya e sua equipa [48], desta vez com a finalidade de detetar a patologia do olho seco com a aplicação de SVM em termogramas e dados estatísticos recolhidos. Na implementação foram utilizadas funções *kernel* na ordem de 1 a 3 juntamente com

a técnica RBF. Os resultados apresentam uma exatidão de 84.76%, contudo o classificador que apresentou a melhor performance foi o KNN.

No ano a seguir, surgiu uma revisão do mesmo trabalho de investigação[49] com melhorias na metodologia e redução das características necessárias para a classificação. Contudo, os resultados mostram que a melhor performance continuava a ser obtida com o classificador KNN (92.5% de exatidão), sendo o SVM o segundo melhor com 85% de exatidão.

Voltando a 2014, um artigo de Milosevic [43], realizado com o intuito de detetar e diagnosticar padrões anormais em termogramas de mama, utilizou NKK, SVM e *Naive Bayes* (NB) para diferenciar padrões anormais dos normais. Como forma de avaliar a performance dos classificadores utilizados, foi realizada uma análise do desempenho por ROC e foram tidos em consideração os fatores exatidão, sensibilidade e especificidade. Os resultados mostram que, para os 40 termogramas utilizados, KNN foi o método que obteve melhor performance com uma precisão de 92.5% seguido do classificador SVM com 85% e por último o classificador *Naive Bayes* com 80%.

Por último, Sathish e sua equipa apresentaram, em 2016 [50], uma nova abordagem na análise de termogramas mamários que consistiu no desenvolvimento de uma segmentação automática. A finalidade consistia em poder realizar uma análise assimétrica em relação ao respectivo lado do termograma. Para as 80 imagens em que foram aplicadas o SVM obteve-se um resultado de 90% para a exatidão, 87% para a sensibilidade e 92.5% para a especificidade.

### 3.5 *K-nearest neighbor*

Classificação por KNN (*K-Nearest Neighbor*) é um método não paramétrico simples e intuitivo utilizado para classificar dados em diferentes classes. Esta classificação é realizada de acordo com a semelhança apresentada por um objecto quando comparado com os  $k$  vizinhos mais próximos. Para um determinado ponto, os objetos na vizinhança mais próxima possuem um peso maior para o cálculo da classificação, ou seja, quanto menor a distância entre o ponto e o vizinho maior o peso na classificação. Desta forma, durante a fase de construção do método, é importante considerar apenas os vizinhos cuja classe à qual pertencem já esteja previamente determinada.

Como forma de representação, o modelo KNN utiliza o espaço multidimensional para caracterizar todos os objetos pretendidos sendo, por isso, representados por vetores posicionados de acordo com a distância calculada entre um determinado objeto e um vizinho. O espaço multidimensional é repartido em regiões conforme as localizações e anotações existentes nos elementos base da fase de construção do modelo. Após a fase de construção, a um novo objecto adicionado irá ser calculado o peso dos  $k$  vizinhos mais próximos e atribuído uma classe.

Tal como já foi mencionado anteriormente, nos artigos relacionados com a patologia de olho seco[48][49] e com a problemática de cancro da mama[43], foram obtidos melhores resultados na aplicação de KNN do que quando aplicado o classificador SVM.

Num estudo de 2016[51], foi utilizado KNN para identificar osteoartrose e artrite reumatóide em termogramas de 15 pacientes. A captura destas imagens seguiu um protocolo restrito que

permitiu a seleção correta dos parâmetros e ROIs pretendidas. Os resultados do estudo permitiram chegar a uma conclusão em relação à propagação das doenças na zona do joelho.

No mesmo ano foi também publicado o trabalho de Glowacz[52]. Neste caso, foi aplicado o classificador KNN para detetar lesões existentes na pele do dedo. Foram utilizadas 15 capturas para a construção do classificador e 60 para a fase de testes do sistema proposto. Nos testes em que foi atribuído  $k=1$  e  $k=3$ , utilizaram-se histogramas e imagens filtradas e obtiveram-se resultados com 100% de sucesso na classificação.

Este classificador também foi utilizado em outras práticas fora de aplicações médicas. O crescimento da utilização de máquinas agrícolas em campos para a agricultura cria um maior perigo de morte ou ferimento para a vida selvagem que possa existir no local. O artigo de Christensen [53] apresenta uma tentativa para a resolução deste problema com a utilização de imagens térmicas para a deteção e classificação automática de vida selvagem. Com a utilização de um classificador KNN foi possível detetar a presença animal nas imagens recolhidas, mais concretamente, o algoritmo utilizado continha como base 140 características animais, 359 não-animais e o parâmetro  $k$  foi definido com o valor 11. Estas informações foram utilizadas para a construção da rede pretendida. Contudo os resultados obtidos não eram satisfatórios uma vez que estavam a ser descartadas as informações temporais das gravações recolhidas. Com a metodologia adotada obteve-se uma exatidão de 84.7% num intervalo de 3 até 6 metros em altitude e 75.2% para o de 10 até 20 metros. A utilização de informações temporais melhorou estes valores percentuais para 93.3% e 77.7% respetivamente.

### 3.6 WEKA

No ano de 2006 foi desenvolvido pela Universidade de Waikato, na Nova Zelândia, o software WEKA (*Waikato Environment for Knowledge Analysis*) com o objetivo de disponibilizar em *open source* a utilização de algoritmos dedicados a *machine learning*[47].

As ferramentas implementadas neste programa disponibilizam ao utilizador a possibilidade de aplicar diretamente os algoritmos a ficheiros com conjunto de dados (*dataset*) ou integrar esses algoritmos com o código java desenvolvido pelos utilizadores.

Atualmente, o WEKA 3.8 é a versão estável mais atualizada e existe a versão 3.9 em fase de desenvolvimento.

Relativamente à sua utilização, para além da já referida publicação de Resmini[45], fora da área da termografia existem outras publicações que relatam a sua usabilidade [54][55][56].

### 3.7 Sumário

Após toda a documentação consultada que relaciona a utilização de classificação em termografia é possível retirar algumas conclusões. Como se pretende selecionar os três melhores classificadores para serem implementados no sistema desta dissertação, as conclusões retiradas da revisão elaborada podem ser apresentadas através de uma pirâmide como a da figura 3.6.




Figura 3.6: Representação das conclusões na revisão de classificação

Por um lado, as redes neurais foram o primeiro classificador a ser adaptado e, por este motivo, é o classificador mais vezes utilizado.

Por outro lado, nos últimos anos têm sido realizados estudos que comparam diversos classificadores e é possível concluir que o classificador que apresenta resultados mais satisfatórios é o KNN, seguido do SVM.





## Capítulo 4

# Design e especificações do sistema

Esta secção tem o intuito de caracterizar as etapas de desenvolvimento do sistema proposto para cumprir a finalidade descrita na secção 1.3.

Para apresentar o sistema idealizado, esta caracterização está subdividida em duas secções sendo elas a análise dos requisitos e a arquitetura do sistema.

### 4.1 Requisitos do sistema

O sistema de informação resultante no final desta dissertação pretende dar resposta ao problema proposto. Dado a complexidade dos objetivos especificados foi necessário definir algumas etapas extremamente necessárias para que o resultado fosse satisfatório:

- Ler e recolher dados a partir dos formatos de ficheiros de imagens térmicas disponibilizados.
- Identificar a localização das ROIs pretendidas.
- Recolher os valores radiométricos em cada ROI.
- Efetuar os cálculos estatísticos necessários para determinar os dados definidos como importantes.
- Criar uma base de dados para armazenar todos os dados recolhidos e calculados.
- Criar ficheiros diferenciados com os parâmetros necessários para a classificação.
- Classificar as imagens utilizando as ferramentas pretendidas.
- Detectar a presença ou ausência de úlceras no pé

Depois de definir estes tópicos e a fim de assegurar que o desenvolvimento desta dissertação corra o melhor possível, foi necessário elaborar os requisitos funcionais e não funcionais com mais detalhe. Com isto, foi previsto um modo de verificar se estão a ser cumpridas todas as condições necessárias para o sucesso da solução a implementar.

As ROI definidas para a identificação são as mesmas da figura 2.7 apresentada no Capítulo 2, secção 2.4.

Neste sentido, na tabela 4.1 estão apresentados os requisitos funcionais do sistema, ou seja, as condições que descrevem as funcionalidades do sistema. Por outro lado, na tabela 4.2 encontram-se os requisitos não funcionais do sistema, isto é, as restrições na implementação dos requisitos funcionais.

Desta forma foi decidido que o sistema seria composto por cinco partes:

1. Extração de dados a partir de formatos proprietários;
2. Processamento de imagem;
3. Identificação das ROIs;
4. Sistema de gestão da base de dados;
5. Classificação.

Tabela 4.1: Requisitos funcionais do sistema

ID	Requisito	Prioridade
F01	Identificar ficheiros no formato .img	Alta
F02	Identificar ficheiros no formato .jpg	Média
F03	Extrair o conteúdo dos <i>bytes</i> correspondentes à <i>TAG: Creator Software</i>	Alta
F04	Determinar o <i>offset</i> para o endereço do início de cada <i>tag</i> para cada tipo de conteúdo da <i>tag Creator Software</i> do formato .img	Alta
F05	Extrair o conteúdo de todas as tags existentes nos ficheiros	Baixa
F06	Extrair metadados do formato do ficheiro	Alta
F07	Extrair metadados das condições ambientais	Alta
F08	Extrair metadados da data e hora do ficheiro	Alta
F09	Extrair metadados do modelo e número de serie da câmara	Alta
F10	Extrair matriz com valores radiométricos dos ficheiros com o formato .img	Alta
F11	Extrair imagem térmicas dos ficheiros com o formato .jpg	Baixa
F12	Calcular valores de temperatura a partir dos dados extraídos	Alta
F13	Aplicar métodos de processamento de imagem de forma a segmentar as áreas dos pés	
F14	Identificar a localização de cada uma das 24 ROIs necessárias	Alta
F15	Cada ROI é composta por 81 pixeis (área quadrada com 9 pixeis de lado)	Alta
F16	Efetuar os cálculos estatísticos importantes para a análise de cada ROI	Alta
F17	Obter o valor absoluto da temperatura, em graus Celsius e em valores radiométricos.	Alta

F18	Calcular, para os valores de temperatura em graus Celsius e radiométrico, o histograma, valor mínimo, máximo, média, mediana, desvio padrão, <i>skewness</i> e <i>kurtosis</i> para cada ROI	Alta
F19	Estabelecer comunicação com a base de dados	Alta
F20	Enviar para a BD os dados extraídos e calculados mencionados nos requisitos F110, F121, F122, F123, F124, F300, F21 e F312	Alta
F22	Guardar o diagnostico de cada ROI	Alta
F23	Criar ficheiros de <i>dataset</i> a partir dos dados armazenados na BD	Alta
F24	Aplicar os diferentes métodos de classificação	Alta
F25	Apresentar os resultados da classificação	Alta

Tabela 4.2: Requisitos não funcionais do sistema

ID	Requisito	Prioridade
NF1	As imagens só podem ser do formato .IMG ou .JPEG radiométrico	Alta
NF2	A constante de Planck B tem de ter um valor no intervalo [1300, 1600]	Alta
NF3	A constante de Planck F tem de ter um valor no intervalo [0.5, 2]	Alta
NF4	A constante de Planck O tem de ter um valor negativo	Alta
NF5	O valor de emissividade lido deverá ser o valor correspondente da emissividade de pele humana que é 0.98	Alta
NF6	A base de dados desenvolvida deverá ser de um DBMS do tipo <i>Open source</i> .	Alta

## 4.2 Arquitetura do sistema

Para maior independência entre as partes divididas, foram criados dois programas com a linguagem de programação C# em Visual Studio[57]. O primeiro programa criado teve como objetivo englobar as parte de extração de dados, processamento de imagem e identificação de ROI, ou seja, contém a parte do processamento de informação que será guardado na base de dados. Com o segundo programa pretendeu-se aplicar diferentes classificadores e analisar os resultados.

Foi escolhido desenvolver os programas na linguagem C# por existirem bibliotecas disponíveis com ferramentas para leitura binária de ficheiros, tratamento de imagens, comunicação com base de dados e classificação.

Para armazenar os dados resultantes do primeiro programa, existiu a necessidade de criar uma base de dados (BD). Dada a revisão de DBMS na secção 2.5 foi decidido que a base de dados mais adequada esta dissertação é a PostgreSQL devido ao facto de ser *opensource*, fácil implementação e de baixo custos de manutenção. Desta forma foi definida a criação de uma BD em PostgreSQL[58] para onde o programa enviasse todos os dados pretendidos para a BD. O segundo programa também estabelecia comunicação com a mesma base de dados a fim de ler os dados

necessários para se proceder à classificação. O DBMS MySQL referido na secção 2.5 é também em *open source* contudo é gerido pela companhia Oracle e por isso não há garantias de ser de livre utilização por tempo ilimitado. Por isso, e no sentido de facilitar a continuidade da utilização desta base de dados no futuro para outros fins, ficou decidido a utilização de PostgreSQL.

Quanto à última parte da divisão feita no sistema, a classificação, foram adotadas duas abordagens. Por um lado, no segundo programa em C#, foram implementados os algoritmos necessários para a aplicação das ferramentas de classificação seleccionadas. Por outro lado, para garantir a possibilidade de se efetuar alguma análise crítica aos resultados obtidos com a implementação, os testes de classificação realizados no programa implementado foram de igual forma realizados no programa WEKA[47]. Por este motivo é que foi criado o requisito funcional F500, para garantir a igualdade dos dados utilizados nas duas metodologias.

De forma a que estas especificações sejam mais facilmente visualizadas, na figura 4.1 encontra-se apresentado o modo de funcionamento e comunicação entre as várias partes definidas para o sistema.

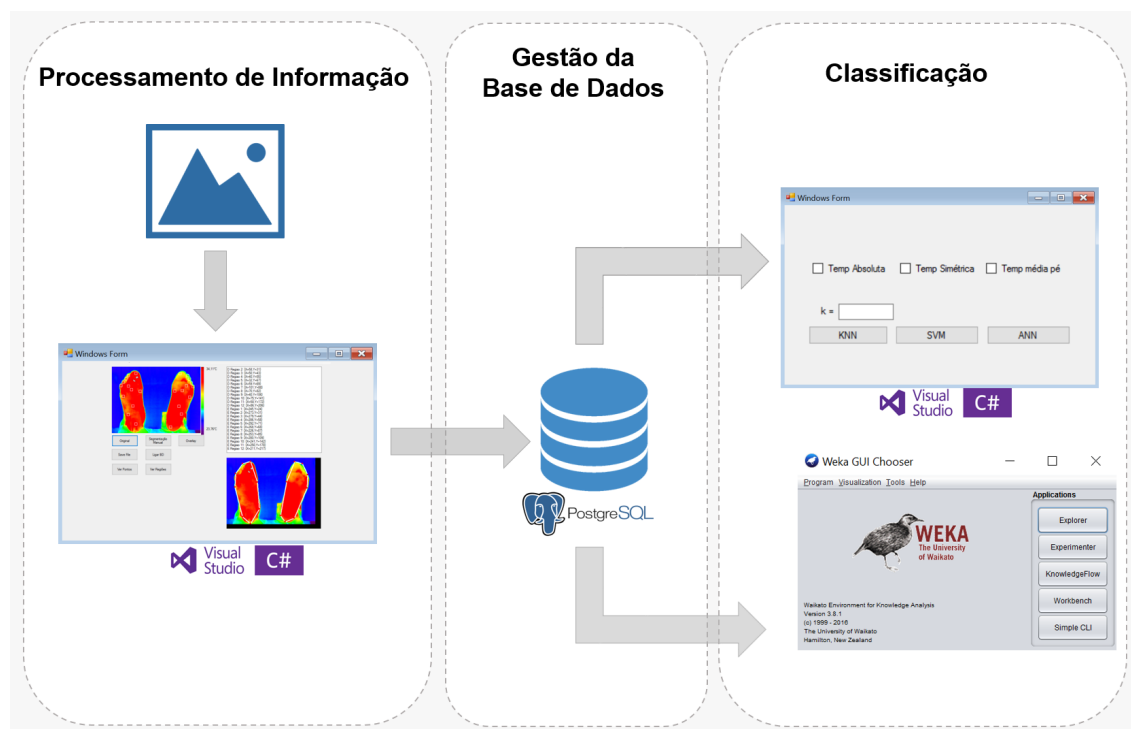


Figura 4.1: Arquitetura do sistema implementado

### 4.3 Sumário

Neste capítulo estão descritas as especificações e divisões de trabalho que foram definidas no início de desenvolvimento deste projeto. As metodologias mais específicas adotadas em cada divisão encontram-se detalhadas nos próximos capítulos, nomeadamente, o capítulo 5 para a recolha

de dados e processamento de dados e no capítulo 6 para a gestão da base de dados e classificação.



## Capítulo 5

# Processamento de informação

Esta secção retrata a metodologia adotada para a extração e preparação de dados que se pretende guardar na base de dados. Este conjunto de funcionalidades pode ser dividido nos seguintes componentes:

1. Extração de dados a partir de formatos proprietários;
2. Processamento de imagem;
3. Identificação das ROIs;

### 5.1 Localização dos metadados em ficheiros Binários

O objetivo principal nesta fase do projeto era o de obter os dados necessários através de uma leitura binária dos ficheiros de imagens. Só com o cumprimento deste objetivo seria possível armazenar os dados necessários para o sucesso deste projeto.

Como já foi referido na secção 2.2.3, com a aplicação de *ExifTool* consegue-se obter o conteúdo de algumas *tags*, ou seja, com esta ferramenta é possível determinar quais as tags possíveis de se encontrar nos ficheiros. O resultado da aplicação desta ferramenta encontra-se no anexo B, mais especificamente, na secção B.1 para o formato .img e na secção B.2 para jpg.

Sabendo que, os formatos de ficheiros de imagens térmicas podem ser processados, por programas informáticos, como ficheiros binários, ou seja, como uma sequência de *bytes*, a primeira etapa desenvolvida foi a de localizar, nestes ficheiros, o endereço dos *bytes* correspondentes aos valores resultantes da aplicação do *ExifTool*.

Neste sentido e com o auxílio de programas editores hexadecimais, como o *Frhead*[59] e o *UltraEdit*[60], capazes de ler os *bytes* dos ficheiros de imagens com diferentes formatos, foi realizado um trabalho de pesquisa e decodificação binária cujos resultados serão apresentados num capítulo mais conveniente. Este processo foi efetuado por inspeção e, por isso, não foi possível criar uma metodologia prévia de como determinar os endereços (localizações) pretendidos.

Após os endereços serem determinados, foi implementado no programa em C# uma classe específica para a leitura dos ficheiros que continha os endereços do conteúdo à extrair dos ficheiros .img e .jpg.

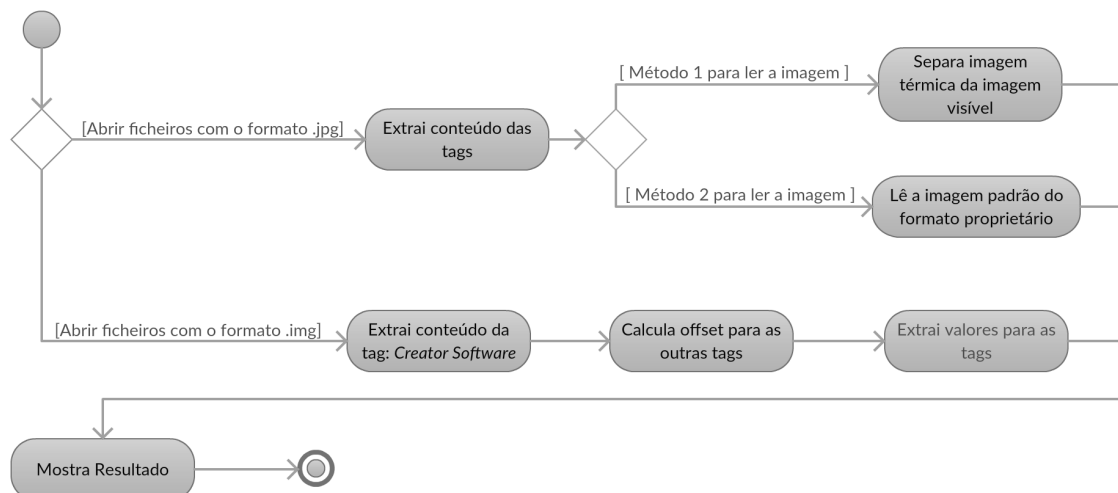


Figura 5.1: Diagrama de atividade para a leitura de imagens térmicas

O diagrama de atividade presente na figura 5.1 esclarece o modo como as imagens são lidas pelo programa criado. Desta forma, os endereços são automaticamente determinados pelo programa. Em capítulos futuros encontram-se esclarecimentos adicionais sobre este funcionamento.

## 5.2 Processamento de imagens

Finalizada a primeira parte do sistema, interessa agora aplicar métodos conhecidos de processamento de imagens para que se consiga segmentar apenas as áreas correspondentes à planta e dedos de ambos os pés. Desta forma, pretendia-se descartar o fundo da imagem (*background*).

Para esta fase, foram criadas duas metodologias. A primeira apresenta uma abordagem mais automática, ou seja, pretendia-se que o programa conseguisse realizar a segmentação com pouca ou nenhuma intervenção por parte do utilizador. No segundo método criado, a segmentação realiza-se com o auxílio de uma camada sobreposta (*overlay*), isto é, são aplicados pontos nas extremidades dos pés de modo a que, depois de esses pontos serem unidos, as duas áreas resultantes sejam dos pés. Os pontos de *overlay* seriam postos nas extremidades pretendidas pelo utilizador, por isso, este segundo método tem mais dependência da intervenção do utilizador.

Na figura 5.2 está representado, através de um diagrama de atividades, o modo como o programa desenvolvido atua em cada um dos métodos descritos anteriormente. As secções seguintes explicam as etapas presentes em cada método.

### 5.2.1 Método 1

Este método é composto pelos seguintes passos:



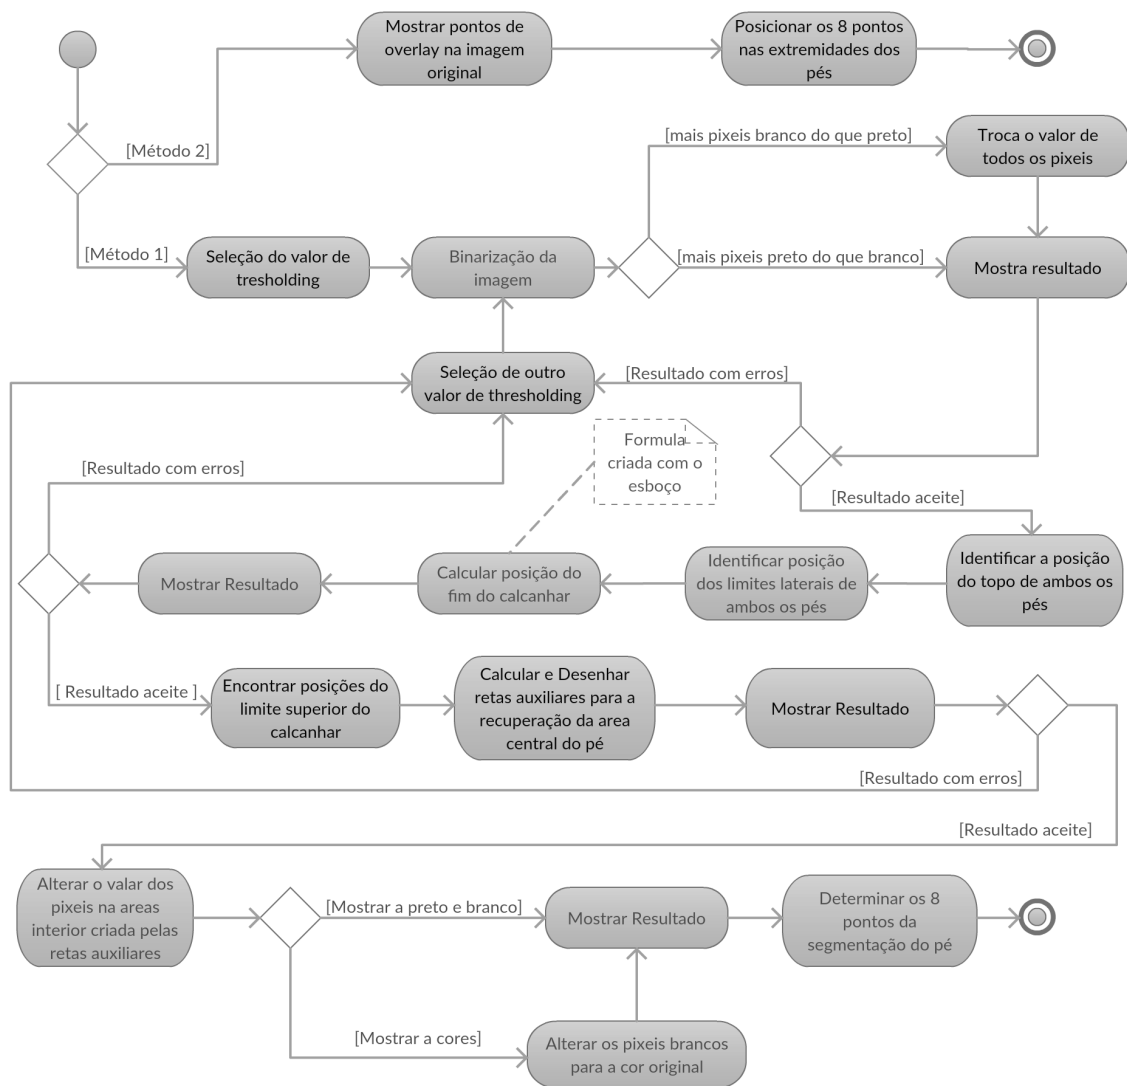


Figura 5.2: Diagrama de atividade para o processamento e segmentação de imagens térmicas

- Binarizar a imagem original
- Encontrar as margens que delimitam os pés
- Recuperar a área central dos pés, perdida na binarização
- Apresentar resultado da segmentação

Os métodos de processamento de imagem aplicados foram necessários para que existisse uma forma de diferenciar os píxeis correspondentes à área plantar do pé dos de *background*. Desta forma, optou-se por aplicar uma binarização por *thresholding*, ou seja, uma segmentação com base no histograma.

A figura 5.3b representa o histograma da imagem térmica na figura 5.3a. Por observação, conclui-se que a maioria dos píxeis representam uma intensidade perto da média que remete para




Figura 5.3: Exemplo de um histograma obtido

a intensidade do fundo. Outra conclusão retirada foi que a temperatura na zona dos pés é maioritariamente mais baixa do que a temperatura de background, com a excepção do centro do pé. Como se pretendia binarizar a imagem de modo a segmentar as plantas dos dois pés, optou-se por aplicar o método de Otsu utilizando para o nível de binarização o valor de temperatura correspondente ao valor de intensidade no pico do histograma. Ao visualizar resultado desta operação verificou-se que a imagem não correspondia ao esperado por isso foram testados vários valores para o *thresholding* até se obter um resultado aceitável que permitisse a continuidade do método. Entre os valores utilizados estavam a média, mediana e alguns valores que se encontravam no intervalo compreendido entre o valor mínimo e a média que se podem observar assinalados a verde na figura 5.4.




Figura 5.4: Offset percentual entre os valores os valores de mínimo e média da temperatura

Depois do processamento de imagem estar concluído, o programa procede para encontrar as margens que delimitam os pés. Começa por identificar o topo dos pés e os limites laterais de ambos os pés. Para o limite inferior, a identificação exigiu mais cuidado porque foi verificado que, mesmo utilizando o *thresholding* mais próximo do ideal, existiam partes segmentadas que não correspondiam a zonas dos pés. Como estas falhas podiam causar a impossibilidade de deteção do limite do calcanhar, foi criada uma fórmula de cálculo para a posição que deveria corresponder ao limite do calcanhar.

A figura 5.5 apresenta um esboço de construção para o desenho de um pé elaborado pelo pintor e matemático Albrecht Dürer. No esboço do centro da figura, pode-se observar que o desvio horizontal (segundo a posição da figura) que existe entre o topo do pé e o ponto colocado




Figura 5.5: Esboço de construção de um pé de Albrecht Dürer, 1513 [6]

no limite lateral do lado interno do pé (na parte mais larga do pé) corresponde a  $1/3$  do tamanho do pé. Esta conclusão foi implementada no programa, tal como foi apresentada no diagrama da figura 5.2.

Depois de localizado o limite inferior do pé, o programa procede para a recuperação da área central do pé. Esta área foi descartada no processo de segmentação porque a temperatura que se verifica na área central é próxima da temperatura de fundo. Para recuperar esta área, o programa procura os pontos a branco na zona do calcanhar, do lado interno e externo do pé, cuja posição fosse a mais próxima da área central do pé. De seguida, no código desenvolvido, seriam criadas duas retas por cada pé. Cada reta criada passa por um destes últimos quatro pontos criados e pelo o ponto do limite do pé do lado respetivo. Desta forma foi criada uma área de recuperação, ou seja, eram alterados para 255 (branco) os píxeis localizados no interior da área criada pelas retas. Caso o utilizador desejasse, o programa tinha ainda a possibilidade de mostrar o resultado da segmentação a cores, isto é, os píxeis a preto continuavam a preto e os píxeis brancos eram convertidos para a cor da figura original.

Por último, eram realizados cálculos no resultado da segmentação para encontrar os oito pontos por pé necessários para a identificação das ROIs. Na secção 5.3 existem mais explicações acerca destes pontos.

Durante a execução de todo este método, o programa apresenta os resultados ao utilizador que decide se os resultados são viáveis ou não. Com esta decisão o utilizador escolhe se pretende que o programa proceda para o passo seguinte ou se quer recuar e realizar a binarização com um valor diferente para o nível de *thresholding*.

### 5.2.2 Método 2

Esta segunda metodologia não aplica técnicas de processamento. A área de cada pé é segmentada com o auxílio de pontos colocados numa camada sobreposta à área de toda a figura. O utilizador tem de colocar estes pontos de *overlay* nos limites do pé em posições concretas. Como estes serão utilizados para a identificação de ROIs, as posições onde os pontos de *overlay* devem ser colocados estão especificados na figura 5.6 presente na secção 5.3.1.

## 5.3 Identificação de ROIs

Depois de a segmentação estar concluída, ambas as metodologias adotadas na parte de processamento de imagem convergem para a determinação de oito pontos necessários para se identificar a localização das ROIs necessárias. Com a determinação destes pontos auxiliares, o programa desenvolvido calcula a localização de cada ROI. Tal como já foi referido nos requisitos do sistema, cada ROI é composta por um conjunto de 81 píxeis, ou seja, um quadrado com 9 píxeis de lado. Seguidamente, é necessário recolher os dados que iram ser armazenados na base de dados.

### 5.3.1 Determinação da localização de cada ROI




Figura 5.6: Localização das ROIs e dos pontos auxiliares

Tal como se pode observar na figura 5.2 após a segmentação é necessário determinar oito pontos na linha delimitadora de cada pé. A figura 5.6 apresenta a localização de cada um desses pontos e de cada ROI em cada pé que se pretende determinar. Nesta fase de desenvolvimento pretende-se que o programa criado identifique as ROIs a partir da posição de cada um dos pontos auxiliares. Na figura 5.7 está apresentado um diagrama de atividade que ilustra os cálculos implementados no código do programa. Tal como se pode observar, primeiro é calculada a ROI do centro de massa com auxílio de funcionais disponíveis para C#. De seguida são determinadas as ROIs mais externas

com a realização dos calculos indicados na figura. Por último são determinadas as ROIs mais internas.

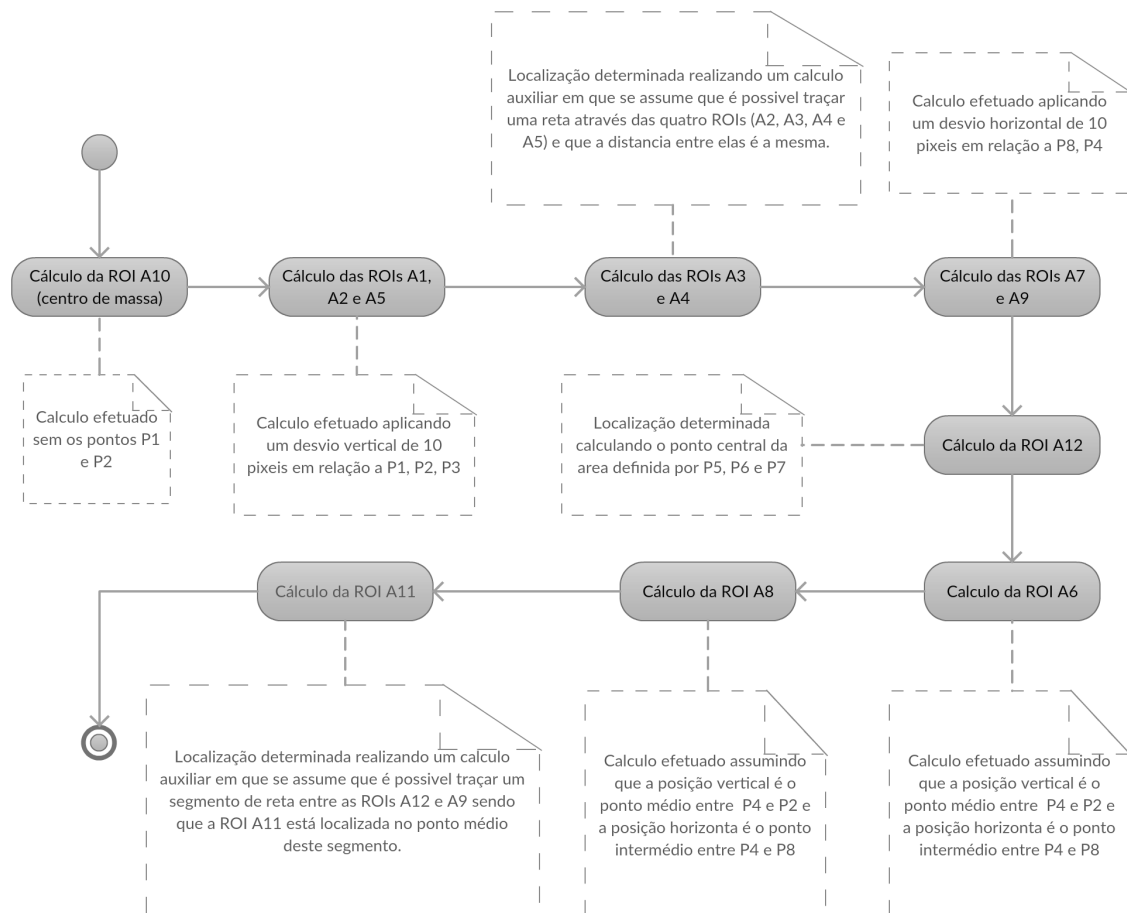


Figura 5.7: Diagrama de atividade para determinação da posição do píxel central de cada ROI

### 5.3.2 Determinação de valores de temperatura

Depois de determinar a localização do píxel central de cada ROI, e de extrair o valor radiométrico de cada píxel em cada ROI, é necessário realizar alguns cálculos da análise estatística. Pretende-se que os cálculos estatísticos sejam realizados para os valores radiométricos e em graus Celsius. Os parâmetros necessários determinar são:

- Mínimo
- Máximo
- Média
- Mediana
- Desvio Padrão

- *Skewness*
- *Kurtosis*

## 5.4 Sumário

Este capítulo apresenta as funcionalidades implementadas no primeiro programa criado na linguagem C# , em que no final são obtidos dados prontos a ser armazenados na BD.

Neste sentido, foram criados, no programa, funções para estabelecer comunicação com a base de dados e enviar, por comando SQL, os dados pretendidos. O processamento é realizado e os resultados são enviados para a base de dados por cada imagem.

No próximo capítulo é explicado a organização existente na base de dados e qual a metodologia adotada para a classificação.

## Capítulo 6

# Gestão da base de dados e classificação

Concluída a fase de preparação dos dados para armazenar na base de dados interessa agora criar uma base de dados para receber a informação.

De seguida estão estabelecidas as condições necessárias para a aplicação de classificadores.

### 6.1 Estrutura da base de dados

Para cumprir os requisitos propostos, a base de dados criada possui apenas três entidades com os atributos especificados no modelo relacional da figura 6.1.

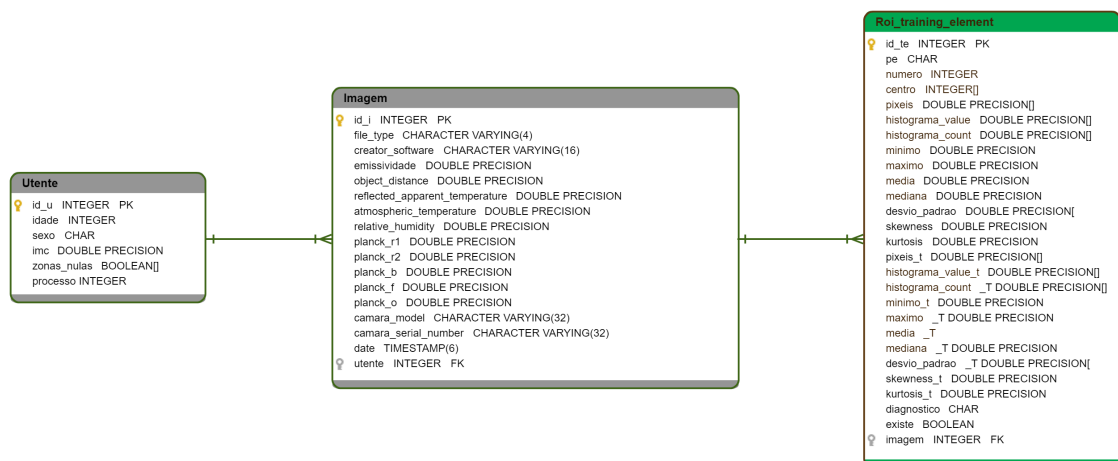


Figura 6.1: Modelo relacional para os elementos de treino da classificação

A entidade “*Roi\_training\_elements*” foi criada para armazenar os dados das ROIs que serão utilizados durante a fase de construção dos classificadores. Para os elementos utilizados nos testes da classificação foi criado outra entidade, “*Roi*”, para as novas ROIs. Esta segunda entidade é homóloga à primeira entidade criada para as ROIs, tal como se pode observar na figura 6.2.

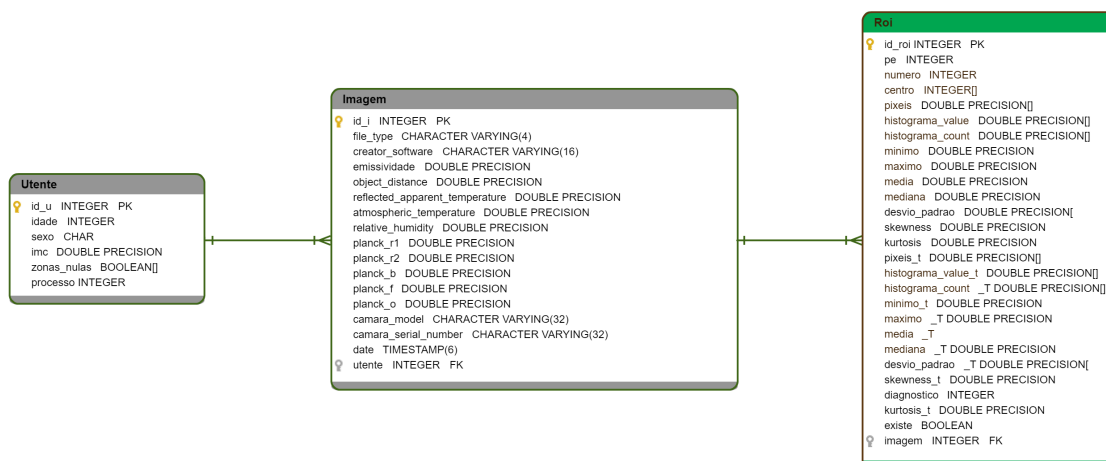


Figura 6.2: Modelo Relacional para os elementos de treino da classificação

No anexo C encontram-se os *scripts* com o código em *SQL* resultante da criação das várias tabelas. De seguida, era necessário povoar a base de dados com os conjuntos de informação obtidos a partir das imagens disponibilizadas e que foram recolhidas em projetos da FEUP nos anos anteriores.

## 6.2 Classificação

Após a criação e povoamento da base de dados estavam reunidas as condições necessárias para se poder implementar a classificação.

Como já foi referido, para esta última parte do sistema, foram adotadas duas metodologias. Por um lado, foi criado um novo programa em C# para a classificação. Por outro, os dados aplicados neste programa foram de igual modo aplicados na ferramenta WEKA. Desta forma seria possível avaliar a classificação do programa criado.

Os métodos que se pretendiam utilizar seriam aqueles onde se verificou melhor performance na revisão feita no capítulo 3, ou seja, os métodos: KNN, SVM e ANN.

### 6.2.1 Programa desenvolvido para a classificação

O programa desenvolvido teria de comunicar com a base de dados para recolher os dados necessários para a classificação. De forma a garantir que os dados utilizados no WEKA e no programa fossem os mesmos, no código implementado teriam de existir funções para gerar ficheiros de *dataset* que pudessem ser utilizados no WEKA. Neste sentido, inicialmente o programa estabelece comunicação com a base de dados, cria dois datasets (um para a fase de construção e outro para a fase de testes), gera ficheiros com o conteúdo, constrói os classificadores, classifica os dados e, por fim, apresenta uma análise dos resultados.



No programa para a classificação foi definido ainda que os elementos (dados das ROIs) de teste do *dataset* deveriam ter uma representação bi-dimensional que seria comum ao modo de funcionamento dos três classificadores.

### 6.2.1.1 KNN

Para a classificação KNN foram implementados no programa alguns passos para testar a classificação dos elementos de teste. Cada novo elemento de teste era colocado na representação criada pelos elementos de construção (treino) e eram determinados os  $k$  vizinhos mais próximos. Para esse cálculo utiliza-se a distância Euclidiana, distância Chebyshev ou a distância Manhattan. A classificação desse elemento de teste seria realizada por votação dos  $k$  vizinhos mais próximos, ou seja, seria atribuído o diagnóstico existente na maioria dos vizinhos.

Na figura 6.3 pode ser visualizado um diagrama de atividade sobre o modo de funcionamento deste classificador. De facto, o programa funciona de forma automática, isto é, o utilizador só precisa de escolher um valor para o  $k$  e qual o teste que pretende realizar. No teste 1, os dataset são compostos pelos valores absolutos da média e da mediana. Por outro lado, no teste 2 são os valores “desvio da média do pé”. Por último, no teste 3, são calculados os valores assimétricos da média e da mediana. Entenda-se por valores “desvio da média do pé” para cada ROI o valor de desvio existente entre essa ROI e o valor da média entre todas as ROIs do respetivo pé.

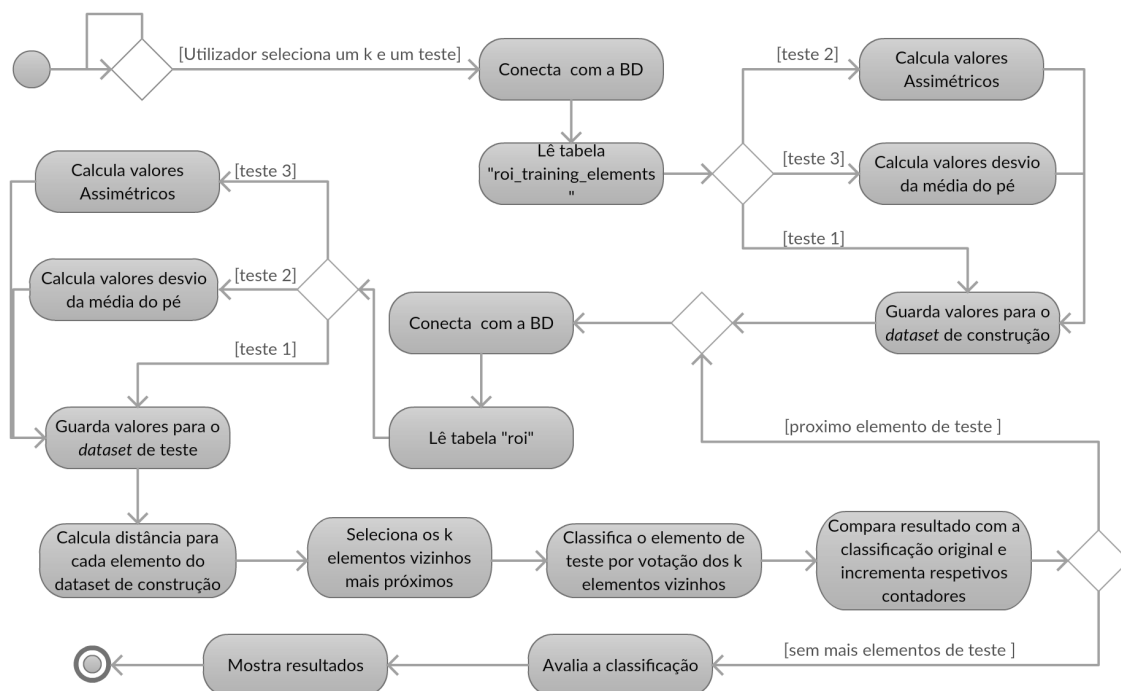


Figura 6.3: Diagrama de atividade para a implementação do classificador KNN

Para o resultado apresentado seria realizada uma análise de acordo com os métodos de avaliação propostos em 3.1.

### 6.2.1.2 SVM

Para este classificador foi adotada uma abordagem como a que foi ilustrada na figura 3.5 presente na secção 3.4 do capítulo de revisão sobre classificação. Ou seja, no programa seriam implementadas funções de forma a criar um hiperplano otimizado para dividir as áreas de representação das classes.

A Microsoft fornece uma biblioteca com métodos para a implementação de SVM[61] que podem ser adaptados no programa desenvolvido. Desta forma as funções não teriam de ser criadas por inteiro.

### 6.2.1.3 ANN

Devido à quantidade de métodos e funções que podem ser aplicados para a construção de uma rede neuronal existe a necessidade de definir uma abordagem a adotar. Contudo, ao ser definida uma abordagem sem o conhecimento de qual é a representação formada pelos elementos de construção, existe o risco de que a abordagem adotada não funcione no caso concreto em que se queira aplicar.

Todavia, o que se pretende desenvolver é uma rede com poucas camadas (3 no máximo) de forma a que a implementação da rede no programa não seja um processo moroso.

## 6.3 Sumário

Depois de especificado o modo de funcionamento de todas as partes do sistema foram implementadas todas as abordagens referidas neste capítulo e no capítulo anterior.

No próximo capítulo serão apresentados todos os resultados obtidos com a aplicação de toda a metodologia do sistema proposta. No capítulo 8 está inserido a análise dos resultados que foram obtidos.

## Capítulo 7

# Resultados

Neste capítulo são apresentados todos os resultados obtidos ao longo do desenvolvimento do sistema proposto para dar cumprimento à finalidade desta dissertação.

### 7.1 Localização dos metadados e leitura binária dos ficheiros

Tal como foi indicado na secção 5.1, foi realizada, com auxílio de um editor hexadecimal, uma pesquisa pelos endereços da localização de alguns metadados. Esta pesquisa foi efetuada tanto em ficheiros .img como em ficheiros .jpg. Depois de serem lidos e convertidos os bytes pretendidos, os endereços foram gravados no primeiro programa desenvolvido em C#.

De seguida estão apresentadas as localizações obtidas, o resultado e modo como foi efetuada a conversão dos bytes lidos.

#### 7.1.1 Ficheiros com o formato .img

<i>Modelo: FLIR A325</i>	0 ... 3	4 ... 19
valor hexadecimal	46 46 46 00	43 41 4d 43 54 52 4c 00 00 00 00 00 00 00 00
metodo de conversão	<i>Conversão ASCII</i>	
Resultado	FFF	CAMCTRL
Nome de Tag	<i>File Type</i>	<i>Creator Software</i>
<i>Modelo: FLIR A65</i>	0 ... 3	4 ... 19
valor hexadecimal	46 46 46 00	52 65 73 65 61 72 63 68 49 52 00 00 00 00 00
metodo de conversão	<i>Conversão ASCII</i>	
Resultado	FFF	ResearchIR
Nome de Tag	<i>File Type</i>	<i>Creator Software</i>

Figura 7.1: Conteúdo dos primeiros 20 bytes dos ficheiros com o formato .img

Em concreto para o formato .img, foram utilizados ficheiros provenientes de 2 modelos de câmaras FLIR: a A325 e a A65. Apesar de ambas apresentarem os ficheiros no mesmo formato, o

conteúdo os primeiro 20 bytes apresentam as diferenças que podem ser observadas na figura 7.1. Por observação de vários ficheiros de ambos os modelos de câmaras, verificou-se que o resto dos metadados que se pretendiam extrair estavam ordenados da mesma forma para ambos os modelos, com a única diferença de que os endereços das *tags* (cujo *CreatorSoftware* = *ReasearchIR*) apresentavam um *offset* extra de 128, provocados por *bytes* com valor nulo entre a tag *CreatorSoftware* e a tag *Emissivity*.

Sobre estas tabelas, é importante esclarecer que os endereços de *offset* apresentados correspondem às posições dos respetivos valores hexadecimais nos ficheiros .img, sendo que em cada posição existe 1 *byte*, ou seja, 8 *bits*. Estes *offsets* são apresentados através da numeração existente na primeira linha de cada tabela.

Nas tabelas seguintes estão apresentados os endereços, o conteúdo e o modo de conversão de todas as tags que se pretendiam encontrar. Estas tabelas remetem para os ficheiros do modelo FLIR A325. O valor do endereço do modelo FLIR A65 sofre um desvio de 128 bytes em todas as posições.

Modelo: FLIR A325	224 ... 227	228 ... 231	232 ... 235	236 ... 239
valor hexadecimal	48 e1 7a 3f	00 00 80 3f	33 93 92 43	33 93 92 43
valor hexadecimal alterado	3f 7a e1 48	3f 80 00 00	43 92 93 33	43 92 93 33
metodo de conversão	IEEE 754 Floating Point			
Resultado em decimal	0.98	1.00	20.0	20.0
Nome de Tag	Emissivity	Object Distance	Reflected Aparent Temperature	Atmospheric Temperature
extensão	FFF			

Figura 7.2: Primeiro conjunto de *tags* encontradas

Modelo: FLIR A325	280 ... 283	284 ... 287	288 ... 289
valor hexadecimal	0b 57 4b 46	9a 79 A9 44	00 00 80 3f
valor hexadecimal alterado	46 4b 57 0b	44 A9 79 9a	3f 80 00 00
metodo de conversão	IEEE 754 Floating Point		
Resultado em decimal	13013.761	1355.8	1.00
Nome de Tag	Planck R1	Planck B	Planck F
extensão	FFF		

Figura 7.3: Segundo conjunto de *tags* encontradas

Modelo: FLIR A325	404 ... 417	436 ... 445	452 ... 460
valor hexadecimal	46 4c 49 52 20 41 33 32 35 20 33 30 48 7a	34 33 34 30 31 2d 30 31 30 30	34 33 34 30 30 30 34 36 30
metodo de conversão	Conversão ASCII		
Resultado	FLIR A325 30Hz	43401-0100	434000460
Nome de Tag	Camara Model	Camera Part Number	Camera Serial Number
extensão	FFF		

Figura 7.4: Terceiro conjunto de *tags* encontradas

<b>Modelo: FLIR A325</b>	968 ... 971	972 ... 975
valor hexadecimal	d7 ea ff ff	dd 7d 29 3c
valor hexadecimal alterado	ff ff ea d7	3c 29 7d dd
metodo de conversão	<i>Complemento Para Dois</i>	<i>IEEE 754 Floating Point</i>
Resultado em decimal	<b>-5417</b>	<b>0.01034495</b>
Nome de Tag	<b>Planck O</b>	<b>Planck R2</b>
extensão	FFF	

Figura 7.5: Quarto conjunto de tags encontradas

<b>Modelo: FLIR A325</b>	1092 ... 1095	1096 ... 1099
valor hexadecimal	ce c5 c7 53	2e 00 00 00
valor hexadecimal alterado	53 c7 c5 ce	00 00 00 2e
metodo de conversão	normal	
Resultado em decimal	1399285187	046
conversão timestamp	<b>2014:05:05 10:19:47.046+00:00</b>	
Nome de Tag	<b>Data/Time Original</b>	
extensão	FFF	

Figura 7.6: Quinto conjunto de tags encontradas

Por último, mas não menos importante, descobriu-se que a matriz da imagem radiométrica era composta por 76800 bytes, ou seja, dado que as imagens apresentadas eram de 320x240 píxeis, o valor da temperatura radiométrica de cada píxel estava inserido numa posição (byte) do ficheiro. O endereço do início da matriz é na posição 1372 para ficheiros cuja tag *Creator Software* apresenta o conteúdo “CAMCTRL” e na posição 2780 para as que apresentem “ResearchIR”.




Figura 7.7: Exemplo da imagem obtida com a leitura dos valores da matriz radiométrica

Com este mapeamento de endereços concluído, foram implementados no código do programa métodos para que fosse possível ler as informações e a imagem existente em cada ficheiro. Este processo seguiu a metodologia apresentada anteriormente na figura 5.1 da secção 5.1.

Nas imagens .img lidas era feita uma conversão para que aparecessem segundo uma paleta de cores *rainbow*, isto é, os píxeis que representassem menor temperatura eram apresentados a azul e os píxeis com a temperatura mais alta seriam apresentados a vermelho. As figuras 7.7a e 7.7b são dois exemplos de imagens .img lidas no programa criado.

Para os ficheiros com o formato .jpg foram também implementadas metodologias no programa para que fosse possível ler imagens. Na prática inicialmente verificou-se que as imagens apresentadas pelos ficheiros .jpg eram compostas por duas imagens: uma visível e outra térmica. Instintivamente foram criadas funções no programa em C# para ler cada uma destas imagens de forma separada e independente. Os resultados obtidos com este processo estão na figura 7.8 .

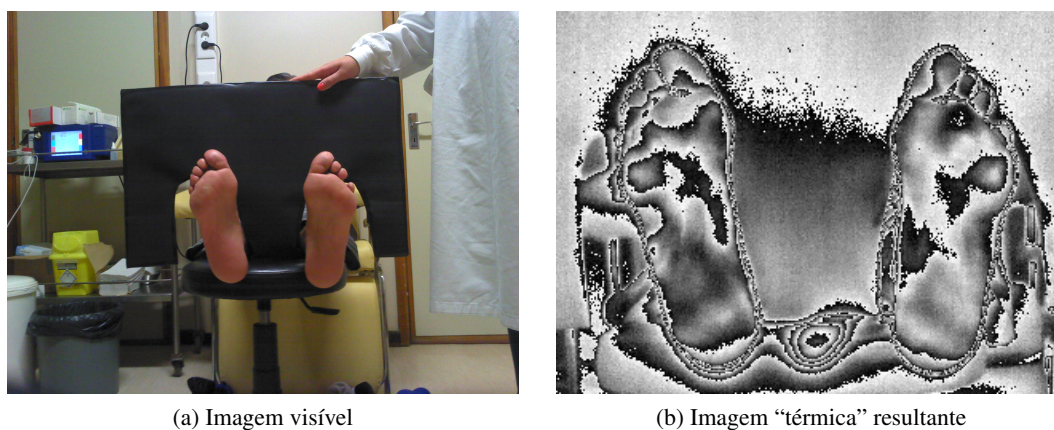


Figura 7.8: Exemplo de imagens obtidas obtidas a partir da separação no formato .jpg

Por outro lado, pretendeu-se também que o programa mostrasse a imagem por inteiro do formato .jpg tendo sido obtido o que se pode observar na figura 7.9.



Figura 7.9: Imagem padrão do formato jpg

Na secção 8.1.2 é explicado de que modo foram analisados estes resultados.

## 7.2 Processamento de imagem

### 7.2.1 Método de segmentação

Finalizada a recolha dos metadados presentes nas imagens térmicas, interessou recolher, por fim, os valores de temperatura para cada uma das 24 ROI's pretendidas. Neste sentido é necessário segmentar a imagem original de modo a que fosse detetado as regiões correspondentes a cada um dos pés. Neste processo foram implementados os dois métodos: um método de identificação mais automático (método 1) e outro de deteção por aplicação de um *overlay* (método 2). As implementações feitas estão de acordo com o que foi especificado no diagrama de atividade da figura 5.2. Na figura 7.10 pretende-se mostrar um resumo dos resultados obtidos com a implementação do método de deteção automática e na figura 7.11 os do método de deteção por *overlay*. De seguida serão apresentados os resultados de alguma etapas mais concretas contidas no primeiro método criado.

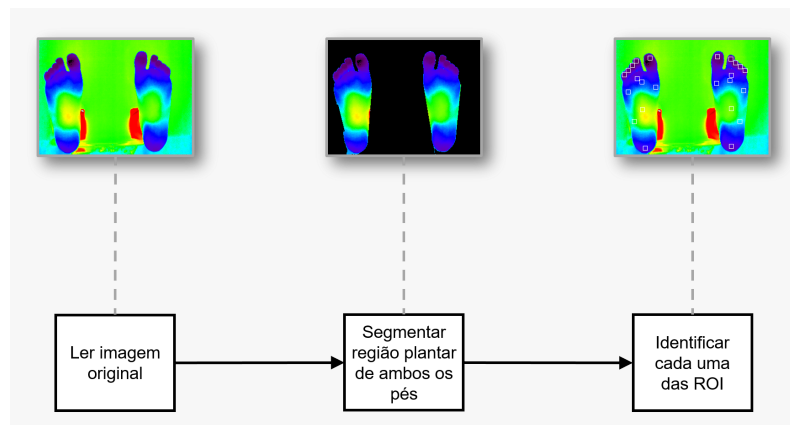


Figura 7.10: Diagrama Detecção Automática




Figura 7.11: Diagrama por Overlay



### 7.2.1.1 Detecção automática




Figura 7.12: Histograma da figura 7.12

A figura 7.12 ilustra um exemplo, já apresentado anteriormente, de uma imagem original lida pelo código desenvolvido. A título de exemplo, as imagens a seguir apresentadas foram obtidas a partir desta.

De forma a que fosse possível diferenciar os píxeis correspondentes à área plantar do pé dos de *background* optou-se por aplicar uma segmentação com base no histograma. Como se pretendia binarizar a imagem de modo a segmentar as plantas dos dois pés e a temperatura nestas regiões é maioritariamente mais baixa do que a temperatura de *background*, optou-se por aplicar o método de Otsu utilizando para o limiar de binarização valores diferentes, os resultados podem ser observados na figura 7.13.




Figura 7.13: Resultados obtidos na Binarização com valores diferentes para o limiar

Posteriormente foram efetuadas outras binarizações variando o valor do limiar de acordo com os desvios criados, como apresentados anteriormente na figura 5.4, tendo sido obtidos os resultados da figura 7.14.

Depois de decidido que deveria ser utilizado o limiar do offset de 80%, o programa procedeu com a metodologia explicada na secção 5.2.1. Na figura 7.15 encontram-se os resultados dos limites detetados para a segmentação do pé e o resultado da segmentação está apresentado na figura 7.16.






Figura 7.14: Outros resultados obtidos na Binarização




Figura 7.15: Limites exteriores e em falta no dorso dos pés.




Figura 7.16: Área recuperada e limites de área em falta

### 7.3 Identificação de ROIs

Nas figuras 7.10 e 7.11 já apresentadas é possível visualizar quais as zonas que foram identificadas da imagem exemplo pelo programa. A título de verificação, no anexo D encontram-se os resultados dos dados obtidos calculados de todas as ROIs para a imagem do exemplo, mais concretamente, na secção D.1 são apresentados os dados em graus Celcius e na D.2 encontram-se em radiométricos. O quadro em baixo apresenta um pequeno excerto dos dados em anexo com os resultados em concreto para a ROI 1 do pé direito.

ROI A1 :

Membro inferior direito:

Centro: {X=68,Y=35}

Minimo: 21,11

Maximo: 21,81

Mediana: 21,44

Media: 21,43

Desvio Padrao: 4,16

Skewness: 8,11385783099942E-06

Kurtosis: -0,983173217715016

Pixeis:

```
21,55  21,61  21,63  21,58  21,60  21,68  21,78  21,79  21,81
21,39  21,55  21,48  21,54  21,64  21,61  21,73  21,73  21,71
21,40  21,48  21,43  21,60  21,51  21,65  21,68  21,65  21,67
21,44  21,46  21,54  21,51  21,48  21,47  21,68  21,56  21,69
21,41  21,51  21,35  21,43  21,45  21,44  21,61  21,47  21,48
21,41  21,38  21,34  21,42  21,40  21,35  21,46  21,34  21,44
21,25  21,23  21,17  21,31  21,22  21,31  21,27  21,23  21,38
21,27  21,24  21,18  21,21  21,26  21,21  21,16  21,22  21,29
21,17  21,28  21,22  21,12  21,11  21,13  21,16  21,16  21,19
```

Histograma:

```
value 21,11 :1  value 21,12 :1  value 21,13 :1  value 21,16 :3  value 21,17 :2
value 21,18 :1  value 21,19 :1  value 21,21 :2  value 21,22 :3  value 21,23 :2
value 21,24 :1  value 21,25 :1  value 21,26 :1  value 21,27 :2  value 21,28 :1
value 21,29 :1  value 21,31 :2  value 21,34 :2  value 21,35 :2  value 21,38 :2
value 21,39 :1  value 21,40 :2  value 21,41 :2  value 21,42 :1  value 21,43 :2
value 21,44 :3  value 21,45 :1  value 21,46 :2  value 21,47 :2  value 21,48 :4
value 21,51 :3  value 21,54 :2  value 21,55 :2  value 21,56 :1  value 21,58 :1
value 21,60 :2  value 21,61 :3  value 21,63 :1  value 21,64 :1  value 21,65 :2
value 21,67 :1  value 21,68 :3  value 21,69 :1  value 21,71 :1  value 21,73 :2
value 21,78 :1  value 21,79 :1  value 21,81 :1
```

## 7.4 Base de dados

Continuando com a mesma imagem exemplo, todas as informações recolhidas, nomeadamente, os dados das ROIs, da imagem e do indivíduo da captura foram armazenadas na base de dados. Este armazenamento foi efetuado pelo programa criado em C#. No código implementado foram inseridos métodos para estabelecer comunicação com a base de dados e depois foi enviada toda a informação por SQL.

Neste sentido, os dados de utente disponíveis na tabela 7.1 resultaram do seguinte código:

```
SELECT * FROM public.utente WHERE id_u=229;
```

Tabela 7.1: Resultados da tabela public.utente presente na base de dados

id_u	idade	sexo	imc	zonas_nulas	processo
229	23	M	21.09	[False, False, False, False, False, False, False, False, False, False, False, False, False, False, False, False, False, False, False, False]	4

Os outros dados das outras tabelas foram guardados seguindo o mesmo processo. Contudo, não é possível apresentar resultados da tabela public.imagem e da tabelas public.roi\_training\_element porque, devido à existência de uma elevada quantidade de atributos, a tabela ficaria ilegível. Esta imagem exemplificada foi inserida na tabela que continha os elementos que foram utilizados para a fase de construção da classificação.

Tabela 7.2: Numero de elementos inseridos na BD

Nome da tabela	Numero de elementos inseridos
public.utente	66
public.imagem	110
public.roi_training_elements	2158
public.roi	480

Todas as imagens utilizadas nesta dissertação foram obtidas em projetos anteriores. No total foram armazenadas 110 imagens. Destas, 90 foram utilizadas para a fase de construção de classificadores e as restantes 20 nos testes. Mais concretamente, das imagens utilizadas no treino da classificação 66 provinham de pessoas saudáveis e 24 de pacientes com úlceras (13 de neuropáticas, 10 neuroisquémicas e 1 isquémica). Nas de teste, 10 pertenciam a indivíduos saudáveis e as restantes 10 provêm de pacientes diabéticos (5 de úlcera neuropática e 5 de neuroisquémica). Em suma, dos 2668 elementos de ROIs armazenadas apenas 100 ROIs eram de úlceras (32 no conjunto para testes e 68 no outro).

## 7.5 Classificação

Para a classificação, tal como foi referido na secção 6.2, foi criado um novo programa em C#. Inicialmente o programa começa por estabelecer comunicação com a base de dados e recolher os conjunto de dados (*datasets*) que iram ser necessários para a classificação. De seguida o programa gera os ficheiros com os datasets que iram ser utilizados para os testes da classificação. Foram realizados testes com os classificadores escolhidos para a implementação, nomeadamente, KNN, SVM e ANN. Os resultados serão apresentados nas próximas secções mas primeiro interessa mostrar a representação bi-dimensional formada pelos datasets criados.

### 7.5.1 Representação bi-dimensional dos dados

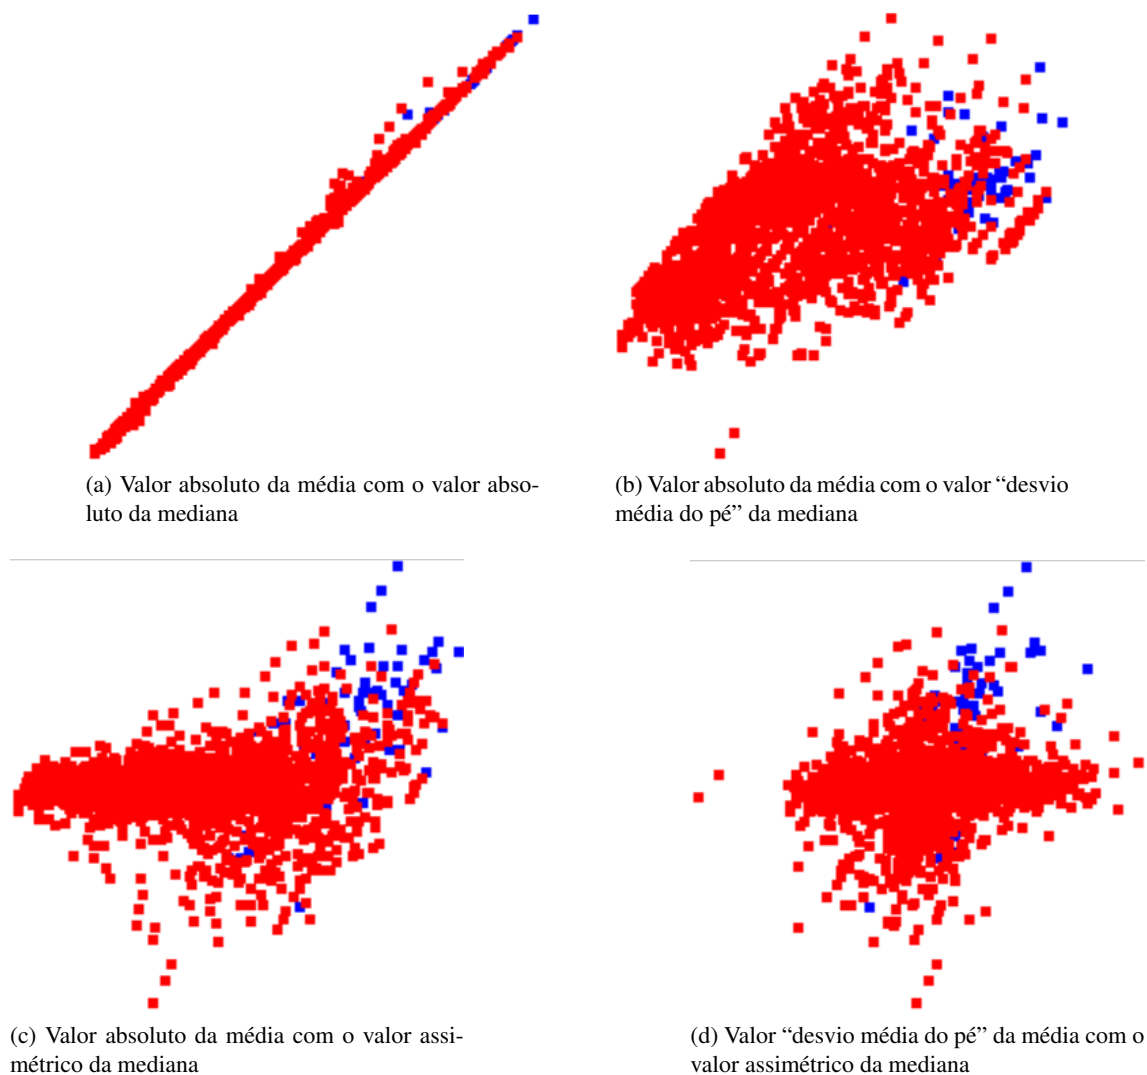


Figura 7.17: Algumas representações bi-dimensionais obtidas

Os dados contidos nos *datasets* criados podiam ser de 3 tipos diferentes: valores absolutos, assimétricos ou média no pé. Os valores absolutos são os valores de temperatura (por exemplo, a média ou mediana) lidos da base de dados e enviados diretamente para o *dataset*. Por valores assimétricos entende-se que, primeiro, é calculado o desvio entre a temperatura da ROI de um pé com a temperatura da ROI contralateral respetiva presente no outro pé e depois este resultado é o valor enviado para o dataset. Nos valores “desvio média do pé” é, também, realizado um calculo de desvio mas, desta vez, é entre a temperatura de uma ROI com a temperatura média entre todas as ROIs do pé respetivo.

Verificou-se que, dependendo do tipo de valores no *dataset* a representação bi-dimensional formada era diferente. As imagens da figura 7.17 mostram algumas representações que foram obtidas.

### 7.5.2 Resultados da classificação

No programa criado foi implementado o classificador KNN de acordo com o que foi especificado na secção 6.2.1.1. Para este classificador foram efetuados 3 testes. Cada teste era composto por valores diferentes nos *datasets*. No primeiro teste foram utilizados os valores absolutos da média e da mediana. No segundo teste utilizaram-se os valores “desvio média do pé” da média e da mediana. Por último, no 3º teste foram utilizados os valores assimétricos da média e da mediana. Apenas os ficheiros de *datasets* do primeiro teste criado foram aplicados tanto no programa desenvolvido como no programa WEKA de forma a poder-se comparar os resultados. Na tabela 7.3 estão apresentados os valores de exatidão obtidos, para vários valores de K, tanto no programa desenvolvido como no WEKA. Os *outputs* integrais podem ser consultados nos anexos, nomeadamente, no anexo E para o programa desenvolvido e no anexo F para o WEKA.

Tabela 7.3: Resultados para o primeiro teste

k		Programa	WEKA
1	exatidão =	90.8%	91.2%
	precisão positiva =	28.0%	6.5%
	precisão negativa =	94.4%	97.4%
3	exatidão =	92.1%	93.4%
	precisão positiva =	14.3%	9.7%
	precisão negativa =	93.2%	99.5%
5	exatidão =	92.5%	92.3%
	precisão positiva =	20.0%	6.5%
	precisão negativa =	93.3%	98.6%
7	exatidão =	92.5%	92.1%
	precisão positiva =	20.0%	9.7%
	precisão negativa =	93.3%	98.1%

O teste 1 foi também efetuado, no WEKA, para os outros dois classificadores que se pretendiam implementar: o SVM e o ANN. Os resultados obtidos encontram-se, parcialmente na tabela 7.4 e integralmente no anexo. Na tabela 7.5 estão apresentados os resultados obtidos dos testes 2 e 3 com o classificador KNN desenvolvido no programa.

Tabela 7.4: Resultados obtidos no programa WEKA

	SVM	ANN
exatidão	93.2%	93.2%
precisão positiva	0%	0%
precisão negativa	100%	100%

Tabela 7.5: Resultados obtidos no programa desenvolvido para o classificador KNN

k		Teste 2	Teste 3
1	exatidão =	89.0%	88.3%
	precisão positiva =	45.4%	23.3%
	precisão negativa =	93.0%	94.7%
3	exatidão =	92.9%	92.9%
	precisão positiva =	33.3%	40.0%
	precisão negativa =	93.3%	93.5%
5	exatidão =	92.9%	93.1%
	precisão positiva =	0%	0%
	precisão negativa =	93.1%	93.1%
7	exatidão =	93.1%	93.1%
	precisão positiva =	0%	0%
	precisão negativa =	93.1%	93.1%

## 7.6 Imagens dos programas desenvolvidos em C#

Nesta secção encontram-se algumas figuras que mostram o modo de funcionamento dos dois programas desenvolvidos, mais especificamente, a figura 7.18 para o primeiro programa e a 7.20 para o segundo programa.

### 7.6.1 Programa 1

A figura 7.18 foi capturada no momento após a abertura de um ficheiro .img. Do lado esquerdo em baixo é possível observar a existência de alguns botões. Estes têm como função apoiar o processamento que se pretende aplicar na imagem. Mais concretamente, o botão “Original” para o processamento atual, retoma a imagem original e apresenta as informações dos metadados lidos do programa. O botão "Segmentação Manual" apresenta a metodologia explicada na secção 5.2.1

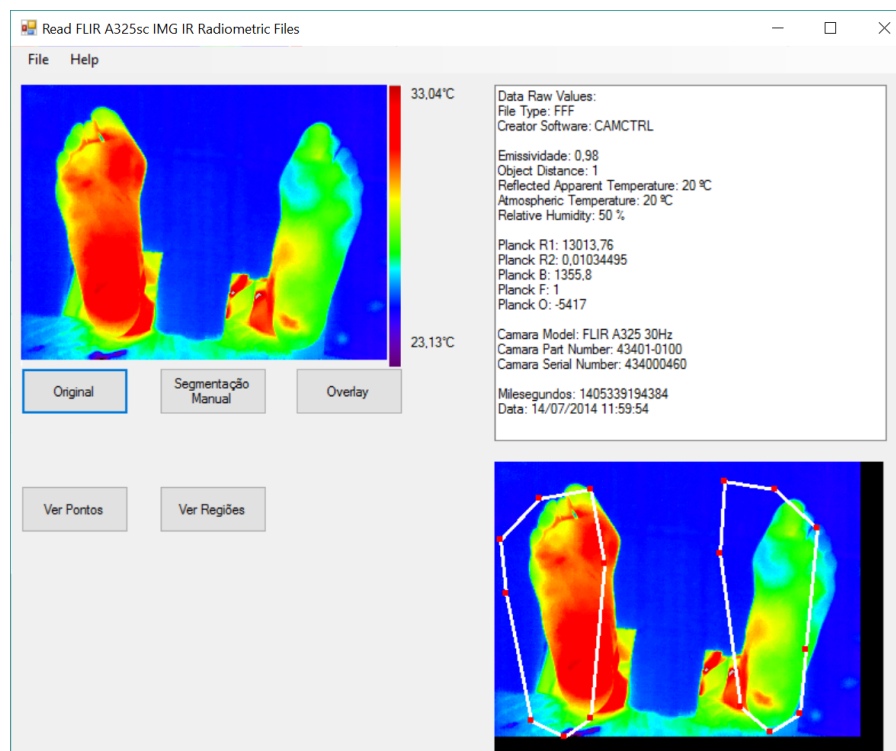


Figura 7.18: Screenshot do primeiro programa

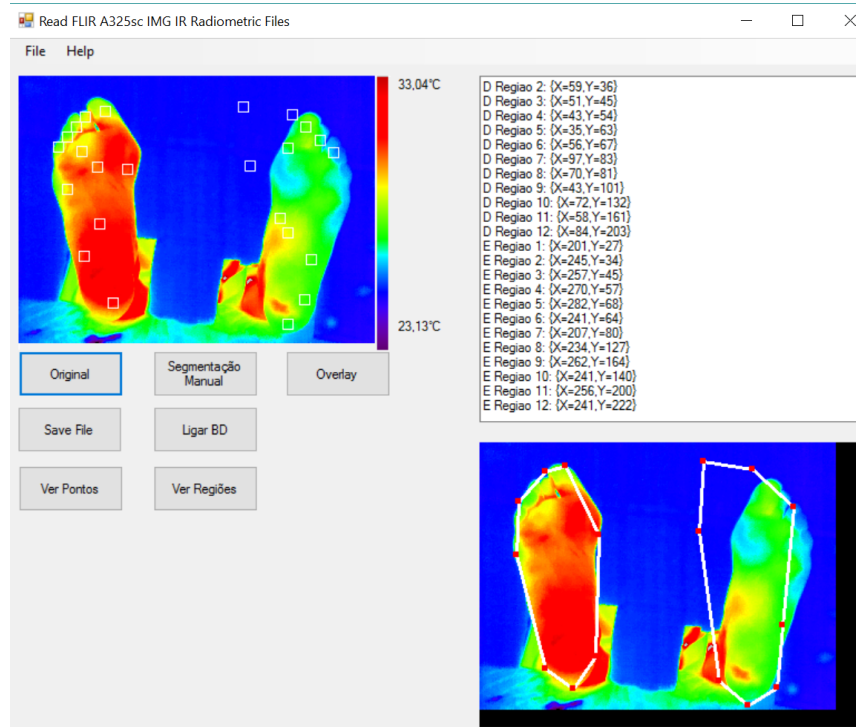


Figura 7.19: Screenshot do método de overlay

e na secção 7.2.1.1 e o botão “Overlay” apresenta a metodologia da secção 5.2.2. Contudo, devido ao facto de existir simplicidade para que o processo de povoação da base de dados fosse mais rápido, os pontos de *overlay* aparecem na imagem da direita em baixo, ou seja, não existe a necessidade de se premir o botão “Overlay”. Deste modo, é possível arrastar os pontos auxiliares para que este fiquem localizados de acordo com o que se pretende e no final, no quadro da direita em cima, são apresentadas as localizações do píxel central de cada ROI. A figura 7.19 mostra este processo. Tal como se pode observar, na imagem da esquerda em cima são apresentadas as ROIs calculadas com os pontos auxiliares colocados pelo utilizador.

### 7.6.2 Programa 2

Tal como já foi explicado, no segundo programa apenas foi implementado classificação por KNN sendo que a sua execução é automática devendo o utilizador especificar um valor para o  $k$  e qual o teste que se pretende realizar. Os resultados da classificação são observáveis na consola do *Visual Studio* mas os mesmos encontram-se no anexo E.




Figura 7.20: Screenshot do segundo programa

## 7.7 Sumário

Neste capítulo foram apresentados os resultados obtidos durante o desenvolvimento desta dissertação. A análise de todos estes resultados encontra-se no próximo capítulo.



## Capítulo 8

# Discussão

Com este capítulo pretende-se esclarecer e explicar ao máximo detalhe os resultados que foram apresentados no capítulo anterior. Existe, também, a necessidade de ser verificado se o sistema resultante desta dissertação corresponde a todos os objetivos propostos.

### 8.1 Localização dos metadados e leitura binária dos ficheiros

#### 8.1.1 Em ficheiros com o formato .img

Em alguns casos, quando se aplicava diretamente os métodos de conversão nos *bytes* ordenados, ou seja, de acordo com a sequência de aparecimento apresentada nos ficheiros .IMG, os valores obtidos não eram os mesmos que se obtiveram com a execução da ferramenta *Exiftool*. Após várias tentativas de criar um método de conversão eficazes, verificou-se que, nesses casos, era necessário inverter a sequência de *bytes*, isto é, tocar a ordem dos *bytes* de cada *tag* sem alterar o valor hexadecimal de cada *byte*, e só depois aplicar o método de conversão. Esta necessidade de inversão acontecia especificamente em todos os casos em que eram utilizados o método de conversão de complemento para dois ou o método de *floating point*. Este último foi estabelecido pelo padrão IEEE 754, criado pelo *Institute of Electrical and Electronics Engineers*.

Após a ultrapassagem deste primeiro obstáculo do desenvolvimento da dissertação, foi possível criar um mapeamento entre as *tags* e o método de conversão que deveria ser utilizado. Para as *tags* cujo resultado são valores decimais, deve-se inverter a ordem dos *bytes* e utilizar o método *IEEE 754 Floating Point*, ou seja, nas *tags*: *Emissivity*, *Object Distance*, *Reflected Aparent Temperature*, *Atmospheric Temperature*, *Planck R1*, *Planck B*, *Planck F* e *Planck R2*. Na *tag Planck O* espera-se um resultado negativo, tal como foi definido pelo requisito não funcional NF4 da tabela 4.2. Neste caso, para a conversão, existe a necessidade de inverter a ordem dos *bytes* e depois deve ser aplicado o método de complemento para dois. Quando o resultado esperado eram caracteres textuais apenas seria necessário converter, com o auxílio de uma tabela ASCII, diretamente o valor hexadecimal de cada *byte* para o caractere correspondente. As *tags* determinadas são apenas as *tags Camera Model*, *Camera Part Number*, *Camera Serial Number* e nas duas *tags* localizadas no início dos ficheiros: a *File Type* e a *Creator Software*. Finalmente, para a *tag Data/Time Original*

primeiro é necessário inverter os bytes (em conjunto de 4) e depois converter os valores hexadecimais para valores decimais. O resultado desta conversão é a data (*timestamp*) em milissegundos que pode ser convertida para uma forma usual de apresentação de uma data.

Após este mapeamento, foram rapidamente determinados os endereços pretendidos. Na secção 7.1.1 do capítulo anterior foram apresentadas figuras que contêm tabelas que pretendem demonstrar um exemplo concreto do método aplicado e dos resultados obtidos. A ordem de apresentação das tabelas segue a ordem de *offset*, ou seja, da posição onde se encontram os bytes respetivos no ficheiro. O valores dos parâmetros das condições ambientais encontram-se nas figuras 7.2, as constantes de *Planck* nas figuras 7.3 e 7.5, as informações sobre a câmara na figura 7.4 e sobre a data da captura na 7.6.

Na realidade, os primeiros endereços descobertos foram os das *tags* da figura 7.1 porque estão localizados no início do ficheiro.

Os valores de temperatura em graus Celsius de cada píxel foram obtidos com a aplicação da expressão 2.5 referida no estado da arte.

### 8.1.2 Em ficheiros com o formato .jpg

Para os ficheiros com o formato .jpg, a pesquisa dos endereços das *tags* foi realizada numa outra dissertação de mestrado, intitulada "Processamento de Imagens Térmicas Para a Avaliação do Risco de Pé Diabético – *FrontOffice*". Essa dissertação foi desenvolvida pela Joana Tavares, decorreu ao mesmo tempo que esta dissertação e foi alvo da mesma orientação.

Apesar de ter sido possível descobrir a localização dos bytes que se pretendiam dos ficheiros .jpg, na prática, não foram enviadas para o dataset quaisquer informações sobre este tipo de ficheiros. Isto aconteceu porque, apesar de terem sido obtidos resultados para os métodos de leitura aplicados (figuras 7.8 e 7.9), em nenhum destes métodos foi possível converter os píxeis lidos na imagem para valores de temperatura. Isto acontece porque a matriz de dados radiométricos se encontra compactada e é necessário identificar o algoritmo de decodificação do mesmo para obter os dados que possam ser convertidos para valores de temperatura como no formato .img, essa tarefa pode revelar-se demorada e complicada. Por este motivo, nesta dissertação, a partir desta parte do sistema, foram apenas utilizadas imagens .img.

## 8.2 Processamento de imagem

Tal como pode ser verificado na secção 7.2.1, foram implementados os dois métodos caracterizados na secção 5.2.

Para o primeiro método, foram verificados alguns contratempos. O primeiro foi que, devido à distribuição de temperatura existente em toda a imagem, não existia à partida um limiar de binarização que por si só permitisse a diferenciação dos pés relativamente ao fundo. Por este motivo foi necessário averiguar qual o melhor valor para o limiar.

No entanto, outros contratempos surgiram, o que levou à necessidade de este método ser complexo, tal como se pôde ver no diagrama de atividade (figura 5.2).

Por um lado, não existiu um padrão rigoroso no ato de captura das imagens que foram disponibilizadas. Em todas as imagens era possível observar as duas plantas dos pés e estas estavam virados para cima. No entanto, na maioria das imagens verificou-se que existiam, especialmente próximo dos cantos, áreas no *background* em que o valor da temperatura era diferente do da maioria do resto do *background*. A existência destas áreas causava que, depois de aplicar a binarização, resultassem zonas segmentadas que não pertenciam a nenhum dos pés. Por sua vez, estas zonas mal segmentadas causavam erros que levavam à impossibilidade de detecção dos limites dos pés e, portanto, não seria possível identificar, posteriormente, as ROIs. A solução encontrada foi a de binarizar a imagem escolhendo um limiar que permitisse a segmentação quase perfeita da metade superior dos pés. Esta escolha levou à discriminação dos píxeis das zonas centrais do pé e a que a parte por baixo do calcanhar fosse segmentada. Contudo, estes erros colaterais podiam ser ultrapassados utilizando a fórmula criada para determinar a localização do fim do calcanhar e recuperar os píxeis da área central dos pés.

Por outro lado, foi também verificado que em alguns casos, especialmente nas imagens de pessoas saudáveis, a temperatura das áreas dos dedos era próxima da temperatura na área de *background*. Como consequência, era impossível diferenciar por binarização os dedos das zonas de fundo mais próximas. Esta consequência inviabilizou todo o método que tinha sido criado e por isso surgiu a necessidade de criar um método alternativo que não dependesse de técnicas de processamento de imagem surgindo assim o método por *overlay*.

Este segundo método tinha como desvantagem o facto de depender de um utilizador para o posicionamento dos pontos de *overlay* necessários para ser possível identificar as ROIs. Mesmo com a perda da possibilidade de tornar o sistema proposto por esta dissertação um sistema autónomo, o método de *overlay* podia ser aplicado em qualquer imagem.

### 8.3 Identificação de ROIs

O método elaborado para calcular a localização precisa de todas as ROIs obteve sucesso em todas as imagens analisadas e permitiu obter o valor de todos os píxeis contidos em cada ROI.

Os cálculos efetuados com os valores lidos da temperatura são extensos e duais. Contudo, obter todos estes valores era um requisito do sistema. Apesar de na prática, só terem sido utilizados os valores da média e mediana, ambos em graus Celsius, para a classificação, todos os valores pretendidos foram recolhidos e armazenados na base de dados, podendo por isso ser utilizados no futuro.

### 8.4 Base de dados

Apesar de a base de dados criada conter uma estrutura simples com apenas 4 entidades, sendo que duas delas são muito semelhantes, tal como foi definido na secção 6.1. Devido à existência de muitas variáveis requisitadas foram criados muitos atributos. Este facto leva à impossibilidade de apresentar convenientemente mais exemplos do conteúdo da base de dados. Contudo, a tabela

7.1 apresenta o exemplo de uma *query* da tabela criada para armazenar a informações acerca das pessoas a quem pertenciam a imagem.

A tabela 7.2 apresenta o número total dos elementos presentes na BD. De facto a entidade “public.utente” apresenta menos elementos do que a entidade “public.imagem”. Isto acontece porque, nas imagens disponibilizadas, encontravam-se, em alguns casos, mais do que uma imagem por indivíduo. O número total de ROIs armazenadas é de 2638 mas, tendo em conta o cálculo auxiliar  $110 * 24 = 2640$ , facilmente é detetado que houve duas ROIs que foram excluídas, ou melhor, que não chegaram a ser gravadas na base de dados. Isto aconteceu porque numas das imagens disponibilizadas ambos ao pés tinham o dedo da ROI A1 amputado, ou seja, estas duas ROIs não existiam. Relativamente a mais dados concretos sobre a quantidade de informação armazenada, é descrito na secção 7.4.

## 8.5 Classificação

Relativamente à classificação, foram implementadas metodologias no segundo programa em C# criado para se conseguir classificar por KNN os dados pretendidos. Tal como explicado na secção 7.5, foram criados *datasets* com tipos de valores diferentes para os testes de classificação. Mais precisamente, na secção 7.5.1, foram especificados quais os valores criados, nomeadamente, valores absolutos, valores assimétricos e “valores média no pé”. Na secção dos resultados são explicados alguns testes de classificação efetuados e são apresentados os resultados obtidos.

Em termos práticos, no código desenvolvido apenas foi implementado o classificador KNN e de acordo com o especificado na metodologia.

Para testar este classificador de forma conveniente, foi realizada, para os mesmos *datasets* criados, classificação com o programa desenvolvido e com o WEKA. Os resultados podem ser consultados na tabela 7.3. Tal como se pode observar, genericamente, os resultados dos dois programas apresentam valores próximos de exatidão, contudo o programa desenvolvido apresenta uma precisão positiva mais alta, ou seja, foram detetadas mais úlceras corretamente.

De facto, verificou-se que o valor de precisão positiva obtido no programa é superior ao valor de precisão obtido no WEKA. Tal deve-se ao facto de no programa desenvolvido terem sido usadas 3 expressões para calcular a distância dos vizinhos e a escolha dos  $k$  mais próximos ter sido feita por uma votação entre os resultados da distancia calculada enquanto que no WEKA foi utilizada a expressão *default* para o cálculo da distância fornecida pelo programa.

Por outro lado, a precisão positiva é, em qualquer caso, sempre superior à negativa. Isto acontece devido ao facto de existirem poucas ROIs com úlcera, nos *dataset* dos elementos de construção, comparativamente ao número de ROIs sem úlceras que existe no mesmo conjunto.

Para os classificadores SVM e ANN, devido ao facto de o tempo disponível para a sua implementação ser reduzido, optou-se por adotar uma metodologia simples. Contudo, os métodos pensados necessitavam que existisse uma separação linear na representação dos dados. Quando foi verificada a representação formada pelo conjunto de elementos que iriam ser utilizados para a construção do classificador (na figura 7.17) verificou-se que não era possível criar uma separação.

Todavia, e para comprovar a impossibilidade de criar uma separação, com o *dataset* criado para teste 1, foram realizadas tentativas no WEKA de aplicar o classificador SVM e o ANN ambas com as configurações *default* fornecidas e utilizando métodos de separação linear. Os resultados obtidos encontram-se na tabela 7.4 e mostram o esperado. O que aconteceu foi que, dada a impossibilidade de se criar uma separação, assumiu-se que todo o espaço pertencia à classe “não úlcera” e todos os dados foram classificados como não tendo úlcera. Por este motivo, obteve-se uma precisão positiva de 0% e precisão negativa de 100%, sendo essa classificação entendida como viciada.

## 8.6 Sumário

Estando concluída a análise dos resultados falta ainda verificar se foram cumpridos todos os objetivos propostos.

O primeiro objetivo a ser cumprido foi o de definir um conjunto de dados para armazenar as imagens recolhidas de pé diabético. Este objetivo foi cumprido logo no processo de elaboração do design do sistema. Na prática foram definidas e armazenadas mais variáveis do que as que foram utilizadas na classificação. Mas este ato de recolha de dados garante mais possibilidade de escalabilidade no futuro.

Os primeiros passos dados na implementação do sistema dão resposta ao primeiro objetivo, ou seja, foi realizado um estudo dos formatos .img e .jpg. Verificou-se que foram obtidos os resultados pretendidos no caso do formato .img. Para o formato .jpg, foi possível recolher os metadados mas ainda não é possível ler os valores da temperatura na imagem.

O terceiro objetivo desta dissertação foi o de desenvolver uma ferramenta de análise avançada com métodos de processamento de imagem. Apesar deste objetivo ter sido cumprido com o método de segmentação automática criado, este método não podia ser aplicado na maioria das imagens que foram disponibilizadas para esta dissertação. Como não era aconselhado descartar imagens para que a classificação resultante do sistema tivesse o maior sucesso possível, foi desenvolvido um método de segmentação por *overlay*.

O quarto objetivo também foi cumprido, a base de dados foi criada e devidamente povoada.

Por último, foram criados e implementados métodos para se aferir a classificação dos dados existentes. Devido ao tempo limitado disponível para desenvolver a classificação apenas foi implementado o classificador KNN mas os resultados obtidos são satisfatórios e, dado ter sido concluído no capítulo de revisão do uso da classificação na termografia que este método é o que apresenta melhores resultados, foram cumpridos todos os objetivos propostos.



## Capítulo 9

# Conclusão

Em título de conclusão, os resultados obtidos são satisfatórios e cumprem com a finalidade proposta. Com o sistema desenvolvido e utilizando ferramentas de classificação consegue-se identificar a presença ou ausência de úlceras associadas à patologia pé diabético. O melhor resultado dos testes de classificação efetuados apresenta um valor percentual de exatidão arredondado para 93% e foi obtido utilizando o programa desenvolvido e o classificador KNN (*K-Nearest Neighbor*).

Como sugestão de trabalho futuro propõe-se o desenvolvimento de técnicas que permitam dar continuidade e escalabilidade ao trabalho que foi desenvolvido. Por um lado, seria interessante e benéfico para a população se as ferramentas desenvolvidas pudessem ser inseridas num sistema de serviços de forma a ser utilizado em práticas clínicas e dar apoio à monitorização ou rastreio do desenvolvimento de úlceras no pé diabético. Por outro lado, o sistema criado pode ser adaptado e utilizado para a deteção de outras patologias com caracterização térmica. Para permitir que no futuro sejam usadas imagens com o formato .jpg é preciso criar um método para descomprimir os valores de temperatura a partir dos ficheiros. Uma das abordagens desta dissertação consistiu em segmentar automaticamente as imagens de forma a identificar as ROIs que se pretendiam. O método criado é funcional contudo em apenas alguns casos. Desta forma sugere-se também a criação de um método mais complexo que possa ser aplicado a qualquer imagem. A fim de serem obtidos melhores resultados sugere-se ainda que sejam extraídos dados de mais imagens e submetidos no conjunto de dados armazenados.





# Referências

- [1] Ana Rita Soares Marques. Diabetic foot thermophysiology characterization. Dissertação de mestrado, Faculdade de Engenharia da Universidade do Porto, 2014. URL: <https://repositorio-aberto.up.pt/bitstream/10216/73680/2/32492.pdf>.
- [2] Joaquim Gabriel [et al.]. *Termografia: imagem médica e síndromes dolorosas*. Lidel - Edições Técnicas, Lisboa, 2016.
- [3] Robert M. Haralick e Linda G. Shapiro. Image segmentation techniques. *Computer Vision, Graphics, and Image Processing*, 29(1):100 – 132, 1985. URL: <http://www.sciencedirect.com/science/article/pii/S0734189X85901537>, doi:[http://dx.doi.org/10.1016/S0734-189X\(85\)90153-7](http://dx.doi.org/10.1016/S0734-189X(85)90153-7).
- [4] Audrey Macdonald, Nina Petrova, Suhail Ainarkar, John Allen, Peter Plassmann, Aaron Whittam, John Bevans, Francis Ring, Ben Kluwe, Rob Simpson, Leon Rogers, Graham Machin, e Mike Edmonds. Thermal symmetry of healthy feet: a precursor to a thermal study of diabetic feet prior to skin breakdown. *Physiological Measurement*, 38(1):33, 2017. URL: <http://stacks.iop.org/0967-3334/38/i=1/a=33>.
- [5] T. Jakubowska, B. Wiecek, M. Wysocki, C. Drews-Peszynski, e M. Strzelecki. Classification of breast thermal images using artificial neural networks. Em *The 26th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, volume 1, páginas 1155–1158, Sept 2004. doi:10.1109/IEMBS.2004.1403370.
- [6] Retirado de:. URL: [http://www.uqtr.quebec.ca/AE/Vol\\_11/libre/Neher.html](http://www.uqtr.quebec.ca/AE/Vol_11/libre/Neher.html) [último acesso em 2017/06/01].
- [7] S. Baranoski e E. A. Ayello. *O essencial sobre o tratamento de feridas: Princípios práticos*. Lusodidacta, 2006.
- [8] URL: <https://db-engines.com/en/ranking> [último acesso em 2017/06/01].
- [9] URL: <https://metacpan.org/pod/distribution/Image-ExifTool/lib/Image/ExifTool/TagNames.pod#FLIR-FFF-Tags> [último acesso em 2017/02/03].
- [10] Sociedade Portuguesa de Diabetologia. Diabetes: Factos e números - O Ano de 2014 - Relatório anual do observatório nacional da diabetes, 2015. Disponível em [http://spd.pt/images/ond\\_2015.pdf](http://spd.pt/images/ond_2015.pdf), acedido a última vez em 03 de Novembro de 2016.
- [11] Petr E. Overhaussen. *Úlceras do pé diabético: Causas, diagnósticos e tratamentos*. Lusociencia, 2012.
- [12] Luís M. Alvim Serra. *Pé Diabético*. Lidel, 2 edição, 9 2008.

- [13] K. Ammer. Thermal imaging as outcome measure. *Thermology international* 16, página 125, 2006.
- [14] E F J Ring e K Ammer. Infrared thermal imaging in medicine. *Physiological Measurement*, 33(3):R33, 2012. URL: <http://stacks.iop.org/0967-3334/33/i=3/a=R33>.
- [15] Liu C van Netten JJ, van Baal JG. Infrared thermal imaging for automated detection of diabetic foot complications. *PMC free article -PubMed*, página 1122–1129, 2013.
- [16] URL: <http://www.flir.com/cvs/americas/pt/content/?id=9610> [último acesso em 2017/06/01].
- [17] R.M. Lawson. *Science in the Ancient World: An Encyclopedia*. ABC-CLIO's history of science series. ABC-CLIO, 2004. URL: <https://books.google.pt/books?id=1AY1ALzh9V0C>.
- [18] Ricardo Vardasca e Ricardo Simoes. Current issues in medical thermography. Em *Topics in medical image processing and computational vision*, páginas 223–237. Springer Netherlands, 2013.
- [19] C. A. Wunderlich. *On the temperature in diseases*. The New Sydenham society, London, 1871. URL: [http://openlibrary.org/books/OL23323445M/On\\_the\\_temperature\\_in\\_diseases](http://openlibrary.org/books/OL23323445M/On_the_temperature_in_diseases).
- [20] Tiago B. Borchardt, Aura Conci, Rita C.F. Lima, Roger Resmini, e Angel Sanchez. Breast thermography from an image processing viewpoint: A survey. *Signal Processing*, 93(10):2785 – 2803, 2013. Signal and Image Processing Techniques for Detection of Breast Diseases. URL: <http://www.sciencedirect.com/science/article/pii/S0165168412002794>, doi:<http://dx.doi.org/10.1016/j.sigpro.2012.08.012>.
- [21] URL: <http://www.flir.eu/home/> [último acesso em 2016/11/29].
- [22] David G. Armstrong, Katherine Holtz-Neiderer, Christopher Wendel, M. Jane Mohler, Heather R. Kimbriel, e Lawrence A. Lavery. Skin temperature monitoring reduces the risk for diabetic foot ulceration in high-risk patients. *The American Journal of Medicine*, 120:1042–1046, 2007. doi:[doi: 10.1016/j.amjmed.2007.06.028](https://doi.org/10.1016/j.amjmed.2007.06.028).
- [23] D. Hernandez-Contreras, H. Peregrina-Barreto, J. Rangel-Magdaleno, e J. Gonzalez-Bernal. Narrative review: Diabetic foot and infrared thermography. *Infrared Physics & Technology*, 78:105 – 117, 2016. URL: <http://www.sciencedirect.com/science/article/pii/S1350449516302389>, doi:<http://dx.doi.org/10.1016/j.infrared.2016.07.013>.
- [24] Virginie Felizardo, Hugo Rodrigues, Nuno C. Garcia, Celina Alexandre, Daniel Oliveira, Paula Sousa, Nuno M. Garcia, e Nuno Pombo. *Metabolic.Care: A Novel Solution Based on a Thermography for Detection of Diabetic Foot*, páginas 113–119. Springer International Publishing, Cham, 2016. URL: [http://dx.doi.org/10.1007/978-3-319-40114-0\\_13](http://dx.doi.org/10.1007/978-3-319-40114-0_13).
- [25] Chanjuan Liu, Jaap J. van Netten, Jeff G. van Baal, Sicco A. Bus, e Ferdi van der Heijden. Automatic detection of diabetic foot complications with infrared thermography by asymmetric analysis. *Journal of Biomedical Optics*, 20(2):026003, 2015. URL: <http://dx.doi.org/10.1117/1.JBO.20.2.026003>, doi:[10.1117/1.JBO.20.2.026003](https://doi.org/10.1117/1.JBO.20.2.026003).

- [26] Y. Liu, A. Polo, M. Zequera, R. Harba, R. Canals, L. Vilcahuamán, e Y. Bello. Detection of diabetic foot hyperthermia by using a regionalization method, based on the plantar angiosomes, on infrared images. Em *2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, páginas 1389–1392, Aug 2016. doi:10.1109/EMBC.2016.7590967.
- [27] URL: <http://www.flir.eu/flirone> [último acesso em 2016/11/29].
- [28] URL: <http://www.sno.phy.queensu.ca/~phil/exiftool/> [último acesso em 2017/02/03].
- [29] AGEMA Infrared Systems AB. Thermovision 550 operative manual, Setembro 1997. URL: <http://modvid.com/images/flir550man.pdf> [último acesso em 2016-11-28].
- [30] U I Bajwa, R Vardasca, F Ring, e P Plassmann. Comparison of boundary detection techniques to improve image analysis in medical thermography. *The Imaging Science Journal*, 58(1):12–19, 2010. URL: <http://dx.doi.org/10.1179/136821909X12520525092846>.
- [31] Ricardo Vardasca, Joaquim Gabriel, Peter Plassmann, Francis Ring, e Carl Jones. Comparison of different image enhancing techniques for medical thermal images. *Journal of Medical Imaging and Health Informatics*, 5(4):709–714, August 2015. doi:doi:10.1166/jmihi.2015.1453.
- [32] N. Otsu. A threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, 9(1):62–66, Jan 1979. doi:10.1109/TSMC.1979.4310076.
- [33] URL: <https://db-engines.com/en/> [último acesso em 2017/06/01].
- [34] M. Sadeghi-Goughari, A. Mojra, e S. Sadeghi. Parameter estimation of brain tumors using intraoperative thermal imaging based on artificial tactile sensing in conjunction with artificial neural network. *Journal of Physics D: Applied Physics*, página 1122–1129, 2016.
- [35] Heikki Mannila David Hand e Padhraic Smyth. *Principles of Data Mining*. The MIT Press, 1ª edição, 2001.
- [36] E.Y.-K. Ng, S.C. Fok, Y.C. Peh, F.C. Ng, e L.S.J. Sim. Computerized detection of breast cancer with artificial intelligence and thermograms. *Journal of Medical Engineering & Technology*, 26(4):152–157, 2002. URL: <http://dx.doi.org/10.1080/03091900210146941>, arXiv:<http://dx.doi.org/10.1080/03091900210146941>, doi:10.1080/03091900210146941.
- [37] E. Y. K. Ng e E. C. Kee. Advanced integrated technique in breast cancer thermography. *Journal of Medical Engineering & Technology*, 32(2):103–114, 2008. URL: <http://dx.doi.org/10.1080/03091900600562040>, arXiv:<http://dx.doi.org/10.1080/03091900600562040>, doi:10.1080/03091900600562040.
- [38] B Jesenšek Papež, M Palfy, e Z Turk. Infrared thermography based on artificial intelligence for carpal tunnel syndrome diagnosis. *Journal of International Medical Research*, 36(6):1363–1370, 2008. PMID: 19094447. URL: <http://dx.doi.org/10.1177/147323000803600625>, arXiv:<http://dx.doi.org/10.1177/147323000803600625>, doi:10.1177/147323000803600625.

- [39] B Jesenšek Papež, M Palfy, M Mertik, e Z Turk. Infrared thermography based on artificial intelligence as a screening method for carpal tunnel syndrome diagnosis. *Journal of International Medical Research*, 37(3):779–790, 2009. PMID: 19589261. URL: <http://dx.doi.org/10.1177/147323000903700321>, arXiv:<http://dx.doi.org/10.1177/147323000903700321>, doi:10.1177/147323000903700321.
- [40] Robert Koprowski. Automatic analysis of the trunk thermal images from healthy subjects and patients with faulty posture. *Computers in Biology and Medicine*, 62:110 – 118, 2015. URL: <http://www.sciencedirect.com/science/article/pii/S0010482515001353>, doi:<http://dx.doi.org/10.1016/j.compbiomed.2015.04.017>.
- [41] Georgia Koukiou e Vassilis Anastassopoulos. Neural networks for identifying drunk persons using thermal infrared imagery. *Forensic Science International*, 252:69 – 76, 2015. URL: <http://www.sciencedirect.com/science/article/pii/S0379073815001681>, doi:<http://dx.doi.org/10.1016/j.forsciint.2015.04.022>.
- [42] Elham Saniei, Saeed Setayeshi, Mohammad Esmaeil Akbari, e Mitra Navid. Parameter estimation of breast tumour using dynamic neural network from thermal pattern. *Journal of Advanced Research*, 7(6):1045 – 1055, 2016. URL: <http://www.sciencedirect.com/science/article/pii/S209012321630039X>, doi:<http://dx.doi.org/10.1016/j.jare.2016.05.005>.
- [43] Marina Milosevic, Dragan Jankovic, e Aleksandar Peulic. Thermography based breast cancer detection using texture features and minimum variance quantization. *EXCLI J*, 13:1204–1215, Nov 2014. 2014-516[PII]. URL: <http://www.ncbi.nlm.nih.gov/pmc/articles/PMC4464488/>.
- [44] Cruz-Ramírez Nicandro, Mezura-Montes Efrén, Ameca-Alducin María Yaneli, Martín-Del-Campo-Mena Enrique, Acosta-Mesa Héctor Gabriel, Pérez-Castro Nancy, Guerra-Hernández Alejandro, Hoyos-Rivera Guillermo de Jesús, e Barrientos-Martínez Rocío Erandi. Evaluation of the diagnostic power of thermography in breast cancer using bayesian network classifiers. *Computational and mathematical methods in medicine*, 2013, 2013.
- [45] Roger Resmini, Tiago B Borchardt, Aura Conci, e Rita CF Lima. Auxílio ao diagnóstico precoce de patologias da mama usando imagens térmicas e técnicas de mineração de dados. *Anais do Computer on the Beach*, páginas 305–314, 2012.
- [46] U. Rajendra Acharya, E. Y. K. Ng, Jen-Hong Tan, e S. Vinitha Sree. Thermography based breast cancer detection using texture features and support vector machine. *Journal of Medical Systems*, 36(3):1503–1510, 2012. URL: <http://dx.doi.org/10.1007/s10916-010-9611-z>, doi:10.1007/s10916-010-9611-z.
- [47] URL: <http://www.cs.waikato.ac.nz/ml/weka/> [último acesso em 2017/06/01].
- [48] U. Rajendra Acharya, Jen Hong Tan, S. Vidya, Sharon Yeo, Cheah Loon Too, Wei Jie Eugene Lim, Kuang Chua Chua, e Louis Tong. Diagnosis of response and non-response to dry eye treatment using infrared thermography images. *Infrared Physics & Technology*, 67:497 – 503, 2014. URL: <http://www.sciencedirect.com/science/article/pii/S135044951400190X>, doi:<http://dx.doi.org/10.1016/j.infrared.2014.09.011>.

- [49] U. Rajendra Acharya, Jen Hong Tan, Joel E.W. Koh, Vidya K. Sudarshan, Sharon Yeo, Cheah Loon Too, Chua Kuang Chua, E.Y.K Ng, e Louis Tong. Automated diagnosis of dry eye using infrared thermography images. *Infrared Physics & Technology*, 71:263 – 271, 2015. URL: <http://www.sciencedirect.com/science/article/pii/S1350449515000869>, doi:<http://dx.doi.org/10.1016/j.infrared.2015.04.007>.
- [50] Dayakshini Sathish, Surekha Kamath, Keerthana Prasad, Rajagopal Kadavigere, e Roshan J. Martis. Asymmetry analysis of breast thermograms using automated segmentation and texture features. *Signal, Image and Video Processing*, páginas 1–8, 2016. URL: <http://dx.doi.org/10.1007/s11760-016-1018-y>, doi:10.1007/s11760-016-1018-y.
- [51] Mrinal Kanti Bhowmik, Shawli Bardhan, Kakali Das, Debotosh Bhattacharjee, e Satyabrata Nath. Pain related inflammation analysis using infrared images. *Proc. SPIE*, 9861:986116–986116–14, 2016. URL: <http://dx.doi.org/10.1117/12.2223425>, doi:10.1117/12.2223425.
- [52] Adam Glowacz e Zygryd Glowacz. Recognition of images of finger skin with application of histogram, image filtration and k-nn classifier. *Biocybernetics and Biomedical Engineering*, 36(1):95 – 101, 2016. URL: <http://www.sciencedirect.com/science/article/pii/S0208521615300073>, doi:<http://dx.doi.org/10.1016/j.bbe.2015.12.005>.
- [53] P. Christiansen, K.A. Steen, R.N. Jørgensen, e H. Karstoft. Automated detection and recognition of wildlife using thermal cameras. *Sensors (Switzerland)*, 14(8):13778–13793, 2014. cited By 12. URL: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-84905263429&doi=10.3390%2fs140813778&partnerID=40&md5=24e126938031975c874f0ca82f080a6a>, doi:10.3390/s140813778.
- [54] Yash R Somnay, Mark Craven, Kelly L McCoy, Sally E Carty, Tracy S Wang, Caprice C Greenberg, e David F Schneider. Improving diagnostic recognition of primary hyperparathyroidism with machine learning. *Surgery*, 161(4):1113–1121, 2017.
- [55] Ignacio Arganda-Carreras, Verena Kaynig, Curtis Rueden, Kevin W Eliceiri, Johannes Schindelin, Albert Cardona, e H Sebastian Seung. Trainable weka segmentation: a machine learning tool for microscopy pixel classification. *Bioinformatics*, página btx180, 2017.
- [56] ARKAPRABHA SAU e ISHITA BHAKTA. Artificial neural network (ann) model to predict depression among geriatric population at a slum in kolkata, india. *Journal of Clinical & Diagnostic Research*, 11(5), 2017.
- [57] URL: <https://www.visualstudio.com> [último acesso em 2017/06/01].
- [58] URL: <https://www.postgresql.org/> [último acesso em 2017/06/01].
- [59] URL: <http://frhed.sourceforge.net/en/> [último acesso em 2017/07/15].
- [60] URL: <https://www.ultraedit.com/> [último acesso em 2017/07/15].
- [61] URL: <https://msdn.microsoft.com/en-us/library/azure/dn905835.aspx> [último acesso em 2017/06/01].



## Anexo A

### Informações *metadata*

Tabela A.1: Informação retirada da extensão .FFF[9]

Tag ID	Tag Name	Writable
'_header'	FFFHeader	FLIR Header
0x0001	RawData	FLIR RawData
0x0005	GainDeadData	FLIR GainDeadData
0x0006	CoarseData	FLIR CoarseData
0x000e	EmbeddedImage	FLIR EmbeddedImage
0x0020	CameraInfo	FLIR CameraInfo
0x0021	MeasurementInfo	FLIR MeasInfo
0x0022	PaletteInfo	FLIR PaletteInfo
0x0023	TextInfo	FLIR TextInfo
0x0024	EmbeddedAudioFile	N
0x0028	PaintData	FLIR PaintData
0x002a	PiP	FLIR PiP
0x002b	GPSInfo	FLIR GPSInfo
0x002c	MeterLink	FLIR MeterLink
0x002e	ParameterInfo	FLIR ParamInfo

Tabela A.2: Informação contida na *Tag CameraInfo* da extensão .FFF

Index1	Tag Name	Writable
32	Emissivity	N
36	ObjectDistance	N
40	ReflectedApparentTemperature	N
44	AtmosphericTemperature	N
48	IRWindowTemperature	N
52	IRWindowTransmission	N
60	RelativeHumidity	N
88	PlanckR1	N
92	PlanckB	N
96	PlanckF	N
112	AtmosphericTransAlpha1	N
116	AtmosphericTransAlpha2	N
120	AtmosphericTransBeta1	N
124	AtmosphericTransBeta2	N
128	AtmosphericTransX	N
144	CameraTemperatureRangeMax	N
148	CameraTemperatureRangeMin	N
152	CameraTemperatureMaxClip	N
156	CameraTemperatureMinClip	N
160	CameraTemperatureMaxWarn	N
164	CameraTemperatureMinWarn	N
168	CameraTemperatureMaxSaturated	N
172	CameraTemperatureMinSaturated	N
212	CameraModel	N
244	CameraPartNumber	N
260	CameraSerialNumber	N
276	CameraSoftware	N
368	LensModel	N
400	LensPartNumber	N
416	LensSerialNumber	N
436	FieldOfView	N
492	FilterModel	N
508	FilterPartNumber	N
540	FilterSerialNumber	N
776	PlanckO	N
780	PlanckR2	N
824	RawValueMedian	N
828	RawValueRange	N
900	DateTimeOriginal	N
912	FocusStepCount	N
1116	FocusDistance	N



Tabela A.3: Informação retirada da extensão .FPF

Index1	Tag Name	Writable
32	FPFVersion	N
36	ImageDataOffset	N
40	ImageType	N
42	ImagePixelFormat	N
44	ImageWidth	N
46	ImageHeight	N
48	ExternalTriggerCount	N
52	SequenceFrameNumber	N
120	CameraModel	N
152	CameraPartNumber	N
184	CameraSerialNumber	N
216	CameraTemperatureRangeMin	N
220	CameraTemperatureRangeMax	N
224	LensModel	N
256	LensPartNumber	N
288	LensSerialNumber	N
320	FilterModel	N
336	FilterPartNumber	N
384	FilterSerialNumber	N
480	Emissivity	N
484	ObjectDistance	N
488	ReflectedApparentTemperature	N
492	AtmosphericTemperature	N
496	RelativeHumidity	N
500	ComputedAtmosphericTrans	N
504	EstimatedAtmosphericTrans	N
508	ReferenceTemperature	N
512	IRWindowTemperature	N
516	IRWindowTransmission	N
584	DateTimeOriginal	N
676	CameraScaleMin	N
680	CameraScaleMax	N
684	CalculatedScaleMin	N
688	CalculatedScaleMax	N
692	ActualScaleMin	N
696	ActualScaleMax	N



## Anexo B

# Resultados da ferramenta *ExifTools*

### B.1 Em ficheiros .img

Tabela B.1: Resultados obtidos com a aplicação de *ExifTool* para uma imagem térmica do tipo .img

Nome	Valor
File Permissions	rw-rw-rw-
File Type	FLIR
File Type Extension	fff
MIME Type	application/unknown
Creator Software	CAMCTRL
Emissivity	0.98
Object Distance	1.00 m
Reflected Apparent Temperature	20.0 C
Atmospheric Temperature	20.0 C
IR Window Temperature	20.0 C
IR Window Transmission	1.00
Relative Humidity	50.0 %
Planck R1	13013.761
Planck B	1355.8
Planck F	1
Atmospheric Trans Alpha 1	0.006569
Atmospheric Trans Alpha 2	0.012620
Atmospheric Trans Beta 1	-0.002276
Atmospheric Trans Beta 2	-0.006670
Atmospheric Trans X	1.900000
Camera Temperature Range Max	120.0 C
Camera Temperature Range Min	-20.0 C

Camera Temperature Max Clip	150.0 C
Camera Temperature Min Clip	-40.0 C
Camera Temperature Max Warn	120.0 C
Camera Temperature Min Warn	-20.0 C
Camera Temperature Max Saturated	150.0 C
Camera Temperature Min Saturated	-60.0 C
Camera Model	FLIR A325 30Hz
Camera Part Number	43401-0100
Camera Serial Number	434000460
Camera Software	12.0.5
Lens Model	FOL18
Field Of View	25.0 deg
Planck O	-5417
Planck R2	0.01034495
Raw Value Median	19359
Raw Value Range	4116
Date/Time Original	2014:05:05 10:19:47.046+00:00
Focus Step Count	0
Focus Distance	2.0 m
Raw Thermal Image Width	320
Raw Thermal Image Height	246
Raw Thermal Image Type	TIFF
Raw Thermal Image	(Binary data 157644 bytes, use -b option to extract)
Peak Spectral Sensitivity	10.6 um

## B.2 Em ficheiros .jpg radiométrico

Tabela B.2: Resultados obtidos com a aplicação de *ExifTool* para uma imagem térmica do tipo .jpg radiométrico

Nome	Valor
File Permissions	rw-rw-rw-
File Type	JPEG
File Type Extension	.jpg
MIME Type	image/jpeg
JFIF Version	1.01

Exif Byte Order	Little-endian (Intel, II)
Make	FLIR Systems AB
Camera Model Name	FLIR E60
Orientation	Horizontal (normal)
X Resolution	72
Y Resolution	72
Resolution Unit	inches
Software	4.10.0
Modify Date	2015:05:25 12:33:38
Y Cb Cr Positioning	Centered
Exposure Time	1/59
Exif Version	0220
Create Date	2015:05:25 12:33:38
Components Configuration	-, Cr, Cb, Y
Subject Distance	1 m
Focal Length	18.0 mm
Image Temperature Max	305
Image Temperature Min	294
Flashpix Version	0100
Color Space	sRGB
Exif Image Width	320
Exif Image Height	240
Digital Zoom Ratio	1
Compression	JPEG (old-style)
Thumbnail Offset	1898
Thumbnail Length	2033
Creator Software	
Emissivity	0.98
Object Distance	1.00 m
Reflected Apparent Temperature	20.0 C
Atmospheric Temperature	25.0 C
IR Window Temperature	20.0 C
IR Window Transmission	1.00
Relative Humidity	50.0
Planck R1	16358.414
Planck B	1424.4
Planck F	1
Atmospheric Trans Alpha 1	0.006569
Atmospheric Trans Alpha 2	0.012620

Atmospheric Trans Beta 1	-0.002276
Atmospheric Trans Beta 2	-0.006670
Atmospheric Trans X	1.900000
Camera Temperature Range Max	120.0 C
Camera Temperature Range Min	-20.0 C
Camera Temperature Max Clip	150.0 C
Camera Temperature Min Clip	-40.0 C
Camera Temperature Max Warn	120.0 C
Camera Temperature Min Warn	-20.0 C
Camera Temperature Max Saturated	150.0 C
Camera Temperature Min Saturated	-60.0 C
Camera Model	FLIR E60
Camera Part Number	64501-0302
Camera Serial Number	64510820
Camera Software	25.0.0
Lens Model	FOL18
Lens Part Number	
Lens Serial Number	
Field Of View	25.0 deg
Filter Model	
Filter Part Number	
Filter Serial Number	
Planck O	-5815
Planck R2	0.011263178
Raw Value Median	19182
Raw Value Range	3246
Date/Time Original	2015:05:25
	12:33:38.325+00:00
Focus Step Count	1673
Focus Distance	1.4 m
Palette Colors	224
Above Color	170 128 128
Below Color	50 128 128
Overflow Color	67 216 98
Underflow Color	41 110 240
Isotherm 1 Color	100 128 128
Isotherm 2 Color	150 32 32
Palette Method	0
Palette Name	Rainbow

Palette	(Binary data 672 bytes, use -b option to extract)
Raw Thermal Image Width	320
Raw Thermal Image Height	240
Raw Thermal Image Type	PNG
Raw Thermal Image	(Binary data 88415 bytes, use -b option to extract)
Real 2 IR	2.39375042915344
Offset X	+34
Offset Y	+14
PiP X1	72
PiP X2	246
PiP Y1	55
PiP Y2	185
Embedded Image Width	2048
Embedded Image Height	1536
Embedded Image Type	JPG
Embedded Image	(Binary data 247105 bytes, use -b option to extract)
Image Width	320
Image Height	240
Encoding Process	Baseline DCT, Huffman coding
Bits Per Sample	8
Color Components	3
Y Cb Cr Sub Sampling	YCbCr4:2:0 (2 2)
Image Size	320x240
Megapixels	0.077
Peak Spectral Sensitivity	10.1 um
Shutter Speed	1/59
Thumbnail Image	(Binary data 2033 bytes, use -b option to extract)
Focal Length	18.0 mm





## Anexo C

# *Scripts de código SQL da criação das tabelas de base de dados*

```
-- Table: public.utente

CREATE TABLE public.utente
(
    id_u bigint NOT NULL DEFAULT nextval('id_u_s'::regclass),
    idade integer,
    sexo "char",
    imc double precision,
    zonas_nulas boolean[],
    processo integer,
    CONSTRAINT "Utente_pkey" PRIMARY KEY (id_u)
)
WITH (
    OIDS = FALSE
)
TABLESPACE pg_default;

ALTER TABLE public.utente
    OWNER to postgres;
```

```
-- Table: public.imagem

CREATE TABLE public.imagem
(
    id_i integer NOT NULL DEFAULT nextval('id_i_s'::regclass),
    file_type character varying(4) COLLATE pg_catalog."default",
    creator_software character varying(16) COLLATE pg_catalog."default",
    emissividade double precision,
    object_distance double precision,
    reflected_apparent_temperature double precision,
    atmospheric_temperature double precision,
    relative_humidity double precision,
```

```

    planck_r1 double precision,
    planck_r2 double precision,
    planck_b double precision,
    planck_f double precision,
    planck_o double precision,
    camara_model character varying(32) COLLATE pg_catalog."default",
    camara_serial_number character varying(32) COLLATE pg_catalog."default",
    date timestamp(6) without time zone,
    utente integer,
    CONSTRAINT "Imagem_pkey" PRIMARY KEY (id_i),
    CONSTRAINT "Imagem_utente_fkey" FOREIGN KEY (utente)
        REFERENCES public.utente (id_u) MATCH SIMPLE
        ON UPDATE NO ACTION
        ON DELETE NO ACTION
)
WITH (
    OIDS = FALSE
)
TABLESPACE pg_default;

ALTER TABLE public.imagem
    OWNER to postgres;

```

```

-- Table: public.roi_training_elements

CREATE TABLE public.roi_training_elements
(
    id_te integer NOT NULL DEFAULT nextval('id_r_s'::regclass),
    pe "char",
    numero integer,
    centro integer[],
    pixeis double precision[],
    histograma_value double precision[],
    histograma_count double precision[],
    minimo double precision,
    maximo double precision,
    media double precision,
    mediana double precision,
    desvio_padrao double precision,
    skewness double precision,
    kurtosis double precision,
    pixeis_t double precision[],
    histograma_t_value double precision[],
    histograma_t_count double precision[],
    minimo_t double precision,
    maximo_t double precision,
    media_t double precision,
    mediana_t double precision,
    desvio_padrao_t double precision,

```

```

        skewness_t double precision,
        kurtosis_t double precision,
        diagnostico "char",
        existe boolean,
        imagem integer,
        CONSTRAINT "TE_pkey" PRIMARY KEY (id_te),
        CONSTRAINT "Roi_imagem_fkey" FOREIGN KEY (imagem)
            REFERENCES public.imagem (id_i) MATCH SIMPLE
            ON UPDATE NO ACTION
            ON DELETE NO ACTION
    )
WITH (
    OIDS = FALSE
)
TABLESPACE pg_default;

ALTER TABLE public.roi_training_elements
    OWNER to postgres;

```

```

-- Table: public.roi

-- DROP TABLE public.roi;

CREATE TABLE public.roi
(
    id_roi integer NOT NULL DEFAULT nextval('id_elements'::regclass),
    pe integer,
    numero integer,
    centro integer[],
    pixels double precision[],
    histograma_value double precision[],
    histograma_count double precision[],
    minimo double precision,
    maximo double precision,
    media double precision,
    mediana double precision,
    desvio_padrão double precision,
    skewness double precision,
    kurtosis double precision,
    pixels_t double precision[],
    histograma_t_value double precision[],
    histograma_t_count double precision[],
    minimo_t double precision,
    maximo_t double precision,
    media_t double precision,
    mediana_t double precision,
    desvio_padrão_t double precision,
    skewness_t double precision,
    kurtosis_t double precision,

```

```
diagnostico integer,
existe boolean,
imagem integer,
CONSTRAINT "roi_pkey" PRIMARY KEY (id_roi),
CONSTRAINT "Roi_imagem_fkey" FOREIGN KEY (imagem)
    REFERENCES public.imagem (id_i) MATCH SIMPLE
    ON UPDATE NO ACTION
    ON DELETE NO ACTION
)
WITH (
    OIDS = FALSE
)
TABLESPACE pg_default;

ALTER TABLE public.roi
    OWNER to postgres;
```

## Anexo D

# Resultados dos dados calculados nas ROIs

### D.1 Em graus Celcius

ROI A1 :

Membro inferior direito:

Centro: {X=68,Y=35}  
Minimo: 21,11  
Maximo: 21,81  
Mediana: 21,44  
Media: 21,43  
Desvio Padrao: 4,16  
Skewness: 8,11385783099942E-06  
Kurtosis: -0,983173217715016

Pixelis:

21,55	21,61	21,63	21,58	21,60	21,68	21,78	21,79	21,81
21,39	21,55	21,48	21,54	21,64	21,61	21,73	21,73	21,71
21,40	21,48	21,43	21,60	21,51	21,65	21,68	21,65	21,67
21,44	21,46	21,54	21,51	21,48	21,47	21,68	21,56	21,69
21,41	21,51	21,35	21,43	21,45	21,44	21,61	21,47	21,48
21,41	21,38	21,34	21,42	21,40	21,35	21,46	21,34	21,44
21,25	21,23	21,17	21,31	21,22	21,31	21,27	21,23	21,38
21,27	21,24	21,18	21,21	21,26	21,21	21,16	21,22	21,29
21,17	21,28	21,22	21,12	21,11	21,13	21,16	21,16	21,19

Histograma:

value 21,11 :1	value 21,12 :1	value 21,13 :1	value 21,16 :3	value 21,17 :2
value 21,18 :1	value 21,19 :1	value 21,21 :2	value 21,22 :3	value 21,23 :2

```

value 21,24 :1  value 21,25 :1  value 21,26 :1  value 21,27 :2  value 21,28 :1
value 21,29 :1  value 21,31 :2  value 21,34 :2  value 21,35 :2  value 21,38 :2
value 21,39 :1  value 21,40 :2  value 21,41 :2  value 21,42 :1  value 21,43 :2
value 21,44 :3  value 21,45 :1  value 21,46 :2  value 21,47 :2  value 21,48 :4
value 21,51 :3  value 21,54 :2  value 21,55 :2  value 21,56 :1  value 21,58 :1
value 21,60 :2  value 21,61 :3  value 21,63 :1  value 21,64 :1  value 21,65 :2
value 21,67 :1  value 21,68 :3  value 21,69 :1  value 21,71 :1  value 21,73 :2
value 21,78 :1  value 21,79 :1  value 21,81 :1

```

Membro inferior esquerdo:

```

Centro: {X=212,Y=31}
Minimo: 21,45
Maximo: 22,16
Mediana: 21,78
Media: 21,78
Desvio Padrao: 4,05
Skewness: -3,86938746412137E-06
Kurtosis: -0,974452681059471

```

Pixelis:

```

22,16  22,05  22,10  22,01  22,03  21,97  22,00  21,96  21,94
22,08  22,01  22,00  21,93  21,98  22,01  21,99  21,88  21,88
21,94  21,91  21,92  21,98  21,97  21,94  21,81  21,86  21,78
21,91  21,90  21,93  21,88  21,83  21,82  21,83  21,83  21,77
21,74  21,72  21,87  21,81  21,73  21,80  21,79  21,80  21,76
21,65  21,75  21,81  21,71  21,64  21,62  21,76  21,73  21,65
21,69  21,74  21,70  21,65  21,62  21,69  21,72  21,59  21,56
21,58  21,62  21,71  21,60  21,51  21,53  21,50  21,51  21,59
21,49  21,45  21,48  21,45  21,53  21,53  21,67  21,51  21,48

```

Histograma:

```

value 21,45 :2  value 21,48 :2  value 21,49 :1  value 21,50 :1  value 21,51 :3
value 21,53 :3  value 21,56 :1  value 21,58 :1  value 21,59 :2  value 21,60 :1
value 21,62 :3  value 21,64 :1  value 21,65 :3  value 21,67 :1  value 21,69 :2
value 21,70 :1  value 21,71 :2  value 21,72 :2  value 21,73 :2  value 21,74 :2
value 21,75 :1  value 21,76 :2  value 21,77 :1  value 21,78 :1  value 21,79 :1
value 21,80 :2  value 21,81 :3  value 21,82 :1  value 21,83 :3  value 21,86 :1
value 21,87 :1  value 21,88 :3  value 21,90 :1  value 21,91 :2  value 21,92 :1
value 21,93 :2  value 21,94 :3  value 21,96 :1  value 21,97 :2  value 21,98 :2
value 21,99 :1  value 22,00 :2  value 22,01 :3  value 22,03 :1  value 22,05 :1
value 22,08 :1  value 22,10 :1  value 22,16 :1

```

ROI A2 :

Membro inferior direito:

Centro: {X=43,Y=45}  
 Minimo: 21,13  
 Maximo: 21,50  
 Mediana: 21,24  
 Media: 21,25  
 Desvio Padrao: 1,51  
 Skewness: 8,78895219260906E-05  
 Kurtosis: 1,80933659475259

Pixelis:

21,27	21,41	21,30	21,34	21,28	21,33	21,33	21,31	21,41
21,37	21,31	21,30	21,31	21,29	21,23	21,21	21,25	21,16
21,13	21,31	21,28	21,26	21,30	21,19	21,22	21,17	21,19
21,21	21,30	21,30	21,29	21,28	21,18	21,21	21,27	21,18
21,27	21,25	21,27	21,22	21,29	21,16	21,18	21,19	21,21
21,14	21,26	21,21	21,23	21,22	21,21	21,20	21,19	21,18
21,28	21,23	21,23	21,23	21,24	21,16	21,18	21,19	21,18
21,19	21,27	21,26	21,21	21,21	21,22	21,25	21,21	21,31
21,23	21,31	21,28	21,21	21,28	21,24	21,29	21,43	21,50

Histograma:

value 21,13 :1	value 21,14 :1	value 21,16 :3	value 21,17 :1	value 21,18 :6
value 21,19 :6	value 21,20 :1	value 21,21 :10	value 21,22 :4	value 21,23 :6
value 21,24 :2	value 21,25 :3	value 21,26 :3	value 21,27 :5	value 21,28 :6
value 21,29 :4	value 21,30 :5	value 21,31 :6	value 21,33 :2	value 21,34 :1
value 21,37 :1	value 21,41 :2	value 21,43 :1	value 21,50 :1	

Membro inferior esquerdo:

Centro: {X=241,Y=38}  
 Minimo: 21,24  
 Maximo: 21,63  
 Mediana: 21,39  
 Media: 21,40  
 Desvio Padrao: 1,31  
 Skewness: 0,000113299807953493  
 Kurtosis: 3,28570077975167

Pixelis:

21,53	21,46	21,43	21,53	21,36	21,51	21,50	21,55	21,63
21,42	21,35	21,40	21,42	21,39	21,38	21,42	21,44	21,56
21,35	21,40	21,36	21,41	21,47	21,39	21,37	21,43	21,43

```

21,33  21,36  21,36  21,40  21,40  21,37  21,40  21,42  21,42
21,34  21,34  21,24  21,40  21,36  21,36  21,37  21,43  21,41
21,36  21,35  21,36  21,38  21,36  21,37  21,36  21,33  21,41
21,38  21,36  21,37  21,40  21,39  21,38  21,39  21,32  21,45
21,36  21,38  21,37  21,39  21,40  21,41  21,40  21,38  21,50
21,38  21,39  21,39  21,41  21,38  21,38  21,34  21,43  21,44

```

Histograma:

```

value 21,24 :1  value 21,32 :1  value 21,33 :2  value 21,34 :3  value 21,35 :3
value 21,36 :12 value 21,37 :6  value 21,38 :9  value 21,39 :7  value 21,40 :9
value 21,41 :5  value 21,42 :5  value 21,43 :5  value 21,44 :2  value 21,45 :1
value 21,46 :1  value 21,47 :1  value 21,50 :2  value 21,51 :1  value 21,53 :2
value 21,55 :1  value 21,56 :1  value 21,63 :1

```

ROI A3 :

Membro inferior direito:

```

Centro: {X=34,Y=53}
Minimo: 21,23
Maximo: 23,18
Mediana: 21,33
Media: 21,38
Desvio Padrao: 5,63
Skewness: 0,000464160836721015
Kurtosis: 35,4340206730961

```

Pixeis:

```

23,18  22,21  21,75  21,53  21,61  21,51  21,51  21,38  21,34
21,70  21,70  21,68  21,47  21,48  21,38  21,37  21,34  21,35
21,48  21,39  21,39  21,36  21,40  21,30  21,34  21,25  21,34
21,38  21,42  21,38  21,35  21,35  21,23  21,24  21,24  21,34
21,30  21,40  21,35  21,34  21,33  21,27  21,32  21,23  21,32
21,31  21,34  21,33  21,25  21,30  21,27  21,26  21,28  21,24
21,29  21,37  21,29  21,26  21,33  21,29  21,30  21,24  21,30
21,25  21,32  21,28  21,26  21,33  21,27  21,32  21,31  21,37
21,26  21,25  21,30  21,24  21,33  21,28  21,35  21,25  21,35

```

Histograma:

```

value 21,23 :2  value 21,24 :5  value 21,25 :5  value 21,26 :4  value 21,27 :3
value 21,28 :3  value 21,29 :3  value 21,30 :6  value 21,31 :2  value 21,32 :4
value 21,33 :5  value 21,34 :7  value 21,35 :6  value 21,36 :1  value 21,37 :3
value 21,38 :4  value 21,39 :2  value 21,40 :2  value 21,42 :1  value 21,47 :1
value 21,48 :2  value 21,51 :2  value 21,53 :1  value 21,61 :1  value 21,68 :1
value 21,70 :2  value 21,75 :1  value 22,21 :1  value 23,18 :1

```



Membro inferior esquerdo:

Centro: {X=249,Y=46}  
 Minimo: 21,43  
 Maximo: 24,96  
 Mediana: 21,52  
 Media: 21,74  
 Desvio Padrao: 13,80  
 Skewness: 0,000296731279294272  
 Kurtosis: 13,2892652432697

Pixeis:

21,44	21,43	22,44	23,87	22,90	22,59	23,08	24,05	24,96
21,46	21,51	22,22	21,60	21,83	21,79	21,85	22,20	22,73
21,61	21,57	21,52	21,56	21,61	21,65	21,77	21,83	21,83
21,55	21,52	21,53	21,51	21,52	21,62	21,60	21,60	21,69
21,50	21,51	21,46	21,50	21,50	21,51	21,53	21,56	21,60
21,50	21,50	21,47	21,47	21,53	21,54	21,47	21,50	21,49
21,49	21,48	21,53	21,48	21,52	21,51	21,50	21,53	21,49
21,49	21,51	21,48	21,49	21,51	21,51	21,53	21,49	21,48
21,53	21,50	21,49	21,51	21,49	21,48	21,50	21,47	21,47

Histograma:

value 21,43 :1	value 21,44 :1	value 21,46 :2	value 21,47 :5	value 21,48 :5
value 21,49 :8	value 21,50 :9	value 21,51 :9	value 21,52 :4	value 21,53 :7
value 21,54 :1	value 21,55 :1	value 21,56 :2	value 21,57 :1	value 21,60 :4
value 21,61 :2	value 21,62 :1	value 21,65 :1	value 21,69 :1	value 21,77 :1
value 21,79 :1	value 21,83 :3	value 21,85 :1	value 22,20 :1	value 22,22 :1
value 22,44 :1	value 22,59 :1	value 22,73 :1	value 22,90 :1	value 23,08 :1
value 23,87 :1	value 24,05 :1	value 24,96 :1		

ROI A4 :

Membro inferior direito:

Centro: {X=23,Y=63}  
 Minimo: 21,43  
 Maximo: 24,73  
 Mediana: 21,58  
 Media: 21,81  
 Desvio Padrao: 16,24  
 Skewness: 0,000255339119968606  
 Kurtosis: 8,32217086722421

Pixeis:

```
24,73 24,56 23,71 22,42 21,81 21,74 21,67 21,64 21,52
24,38 23,66 22,34 21,66 21,62 21,60 21,59 21,48 21,49
23,93 22,37 21,65 21,62 21,58 21,49 21,48 21,48 21,44
22,87 21,61 21,55 21,51 21,51 21,52 21,57 21,50 21,43
21,94 21,61 21,54 21,52 21,56 21,58 21,54 21,53 21,53
21,68 21,50 21,49 21,52 21,51 21,52 21,54 21,51 21,59
21,50 21,51 21,55 21,55 21,56 21,59 21,54 21,57 21,57
21,53 21,58 21,58 21,58 21,61 21,65 21,63 21,63 21,76
21,59 21,57 21,59 21,60 21,63 21,60 21,65 21,64 21,63
```

Histograma:

```
value 21,43 :1 value 21,44 :1 value 21,48 :3 value 21,49 :3 value 21,50 :3
value 21,51 :5 value 21,52 :5 value 21,53 :3 value 21,54 :4 value 21,55 :3
value 21,56 :2 value 21,57 :4 value 21,58 :5 value 21,59 :5 value 21,60 :3
value 21,61 :3 value 21,62 :2 value 21,63 :4 value 21,64 :2 value 21,65 :3
value 21,66 :1 value 21,67 :1 value 21,68 :1 value 21,74 :1 value 21,76 :1
value 21,81 :1 value 21,94 :1 value 22,34 :1 value 22,37 :1 value 22,42 :1
value 22,87 :1 value 23,66 :1 value 23,71 :1 value 23,93 :1 value 24,38 :1
value 24,56 :1 value 24,73 :1
```

Membro inferior esquerdo:

```
Centro: {X=259,Y=54}
Minimo: 21,49
Maximo: 24,08
Mediana: 21,75
Media: 21,81
Desvio Padrao: 7,03
Skewness: 0,000467143123065288
Kurtosis: 37,8133144776919
```

Pixeis:

```
21,49 21,56 22,06 21,94 21,94 21,96 22,17 22,72 24,08
21,49 21,59 21,69 21,68 21,69 21,92 21,95 22,15 22,35
21,56 21,64 21,66 21,70 21,68 21,69 21,79 21,89 21,88
21,70 21,70 21,68 21,67 21,67 21,72 21,79 21,81 21,93
21,66 21,73 21,67 21,67 21,73 21,71 21,79 21,78 21,81
21,75 21,67 21,69 21,66 21,73 21,74 21,76 21,76 21,77
21,71 21,79 21,71 21,74 21,72 21,74 21,77 21,77 21,78
21,82 21,75 21,85 21,82 21,78 21,70 21,76 21,76 21,75
21,86 21,86 21,85 21,80 21,76 21,76 21,79 21,70 21,57
```

Histograma:

```

value 21,49 :2  value 21,56 :2  value 21,57 :1  value 21,59 :1  value 21,64 :1
value 21,66 :3  value 21,67 :5  value 21,68 :3  value 21,69 :4  value 21,70 :5
value 21,71 :3  value 21,72 :2  value 21,73 :3  value 21,74 :3  value 21,75 :3
value 21,76 :6  value 21,77 :3  value 21,78 :3  value 21,79 :5  value 21,80 :1
value 21,81 :2  value 21,82 :2  value 21,85 :2  value 21,86 :2  value 21,88 :1
value 21,89 :1  value 21,92 :1  value 21,93 :1  value 21,94 :2  value 21,95 :1
value 21,96 :1  value 22,06 :1  value 22,15 :1  value 22,17 :1  value 22,35 :1
value 22,72 :1  value 24,08 :1

```

ROI A5 :

Membro inferior direito:

```

Centro: {X=14,Y=71}
Minimo: 21,36
Maximo: 24,63
Mediana: 21,70
Media: 22,18
Desvio Padrao: 22,25
Skewness: 0,000124197407329834
Kurtosis: 0,757050242421582

```

Pixeis:

```

24,63  24,59  24,19  23,30  22,26  22,17  21,92  21,86  21,62
24,62  24,48  23,42  22,24  21,89  21,89  21,65  21,63  21,62
24,46  24,06  22,65  21,88  21,84  21,76  21,64  21,62  21,61
24,41  23,50  22,24  21,82  21,66  21,73  21,62  21,50  21,57
24,21  23,00  21,88  21,80  21,59  21,71  21,62  21,54  21,52
23,80  22,51  21,81  21,72  21,51  21,58  21,52  21,48  21,53
23,49  22,27  21,70  21,65  21,49  21,61  21,44  21,36  21,45
23,44  22,10  21,64  21,59  21,45  21,54  21,44  21,50  21,42
23,32  22,01  21,57  21,60  21,54  21,49  21,47  21,42  21,52

```

Histograma:

```

value 21,36 :1  value 21,42 :2  value 21,44 :2  value 21,45 :2  value 21,47 :1
value 21,48 :1  value 21,49 :2  value 21,50 :2  value 21,51 :1  value 21,52 :3
value 21,53 :1  value 21,54 :3  value 21,57 :2  value 21,58 :1  value 21,59 :2
value 21,60 :1  value 21,61 :2  value 21,62 :5  value 21,63 :1  value 21,64 :2
value 21,65 :2  value 21,66 :1  value 21,70 :1  value 21,71 :1  value 21,72 :1
value 21,73 :1  value 21,76 :1  value 21,80 :1  value 21,81 :1  value 21,82 :1
value 21,84 :1  value 21,86 :1  value 21,88 :2  value 21,89 :2  value 21,92 :1
value 22,01 :1  value 22,10 :1  value 22,17 :1  value 22,24 :2  value 22,26 :1
value 22,27 :1  value 22,51 :1  value 22,65 :1  value 23,00 :1  value 23,30 :1
value 23,32 :1  value 23,42 :1  value 23,44 :1  value 23,49 :1  value 23,50 :1

```

value 23,80 :1 value 24,06 :1 value 24,19 :1 value 24,21 :1 value 24,41 :1  
 value 24,46 :1 value 24,48 :1 value 24,59 :1 value 24,62 :1 value 24,63 :1

Membro inferior esquerdo:

Centro: {X=267,Y=62}  
 Minimo: 21,57  
 Maximo: 22,43  
 Mediana: 21,76  
 Media: 21,79  
 Desvio Padrao: 3,01  
 Skewness: 0,000185099513904829  
 Kurtosis: 6,89099675717029

Pixeis:

21,57	21,75	21,76	21,74	21,72	21,89	21,89	22,03	22,43
21,80	21,76	21,70	21,73	21,74	21,69	21,77	21,82	21,97
21,82	21,78	21,71	21,72	21,71	21,58	21,73	21,76	21,90
21,83	21,77	21,74	21,75	21,72	21,72	21,71	21,72	21,77
21,84	21,78	21,77	21,73	21,60	21,64	21,63	21,74	21,75
21,92	21,81	21,75	21,69	21,68	21,73	21,71	21,65	21,76
22,01	21,77	21,79	21,78	21,72	21,69	21,68	21,71	21,77
22,10	21,88	21,91	21,84	21,79	21,68	21,75	21,74	21,75
22,05	22,11	21,77	22,14	21,84	21,82	21,72	21,77	21,80

Histograma:

value 21,57 :1 value 21,58 :1 value 21,60 :1 value 21,63 :1 value 21,64 :1  
 value 21,65 :1 value 21,68 :3 value 21,69 :3 value 21,70 :1 value 21,71 :5  
 value 21,72 :7 value 21,73 :4 value 21,74 :5 value 21,75 :6 value 21,76 :4  
 value 21,77 :8 value 21,78 :3 value 21,79 :2 value 21,80 :2 value 21,81 :1  
 value 21,82 :3 value 21,83 :1 value 21,84 :3 value 21,88 :1 value 21,89 :2  
 value 21,90 :1 value 21,91 :1 value 21,92 :1 value 21,97 :1 value 22,01 :1  
 value 22,03 :1 value 22,05 :1 value 22,10 :1 value 22,11 :1 value 22,14 :1  
 value 22,43 :1

ROI A6 :

Membro inferior direito:

Centro: {X=41,Y=76}  
 Minimo: 22,21  
 Maximo: 22,69  
 Mediana: 22,39  
 Media: 22,42  
 Desvio Padrao: 2,77

Skewness: 3,00279911918709E-05

Kurtosis: -0,938542102671738

Pixeis:

```
22,21 22,25 22,27 22,27 22,28 22,32 22,31 22,35 22,31
22,25 22,28 22,29 22,38 22,27 22,28 22,30 22,27 22,34
22,23 22,27 22,34 22,35 22,38 22,33 22,33 22,37 22,38
22,24 22,30 22,25 22,31 22,36 22,41 22,49 22,40 22,42
22,30 22,40 22,42 22,46 22,41 22,42 22,49 22,50 22,54
22,33 22,34 22,36 22,50 22,53 22,50 22,60 22,55 22,55
22,38 22,37 22,46 22,50 22,45 22,56 22,55 22,58 22,60
22,33 22,46 22,43 22,46 22,56 22,57 22,59 22,58 22,66
22,34 22,39 22,52 22,55 22,59 22,57 22,62 22,69 22,66
```

Histograma:

```
value 22,21 :1 value 22,23 :1 value 22,24 :1 value 22,25 :3 value 22,27 :5
value 22,28 :3 value 22,29 :1 value 22,30 :3 value 22,31 :3 value 22,32 :1
value 22,33 :4 value 22,34 :4 value 22,35 :2 value 22,36 :2 value 22,37 :2
value 22,38 :4 value 22,39 :1 value 22,40 :2 value 22,41 :2 value 22,42 :3
value 22,43 :1 value 22,45 :1 value 22,46 :4 value 22,49 :2 value 22,50 :4
value 22,52 :1 value 22,53 :1 value 22,54 :1 value 22,55 :4 value 22,56 :2
value 22,57 :2 value 22,58 :2 value 22,59 :2 value 22,60 :2 value 22,62 :1
value 22,66 :2 value 22,69 :1
```

Membro inferior esquerdo:

Centro: {X=239,Y=74}

Minimo: 22,41

Maximo: 23,06

Mediana: 22,67

Media: 22,70

Desvio Padrao: 3,97

Skewness: 8,48770561628323E-06

Kurtosis: -1,08324740554614

Pixeis:

```
22,51 22,42 22,48 22,43 22,43 22,42 22,41 22,53 22,48
22,58 22,49 22,51 22,43 22,42 22,54 22,45 22,46 22,51
22,81 22,49 22,60 22,53 22,57 22,54 22,61 22,61 22,58
22,66 22,61 22,67 22,57 22,64 22,61 22,64 22,62 22,58
22,87 22,71 22,72 22,72 22,71 22,66 22,68 22,62 22,62
22,86 22,73 22,80 22,75 22,71 22,67 22,66 22,77 22,68
22,90 22,88 22,85 22,84 22,83 22,78 22,80 22,67 22,85
23,01 22,98 22,86 22,86 22,88 22,88 22,94 22,84 22,88
23,06 23,02 22,96 22,89 22,93 22,96 22,89 22,88 22,90
```

Histograma:

```
value 22,41 :1  value 22,42 :3  value 22,43 :3  value 22,45 :1  value 22,46 :1
value 22,48 :2  value 22,49 :2  value 22,51 :3  value 22,53 :2  value 22,54 :2
value 22,57 :2  value 22,58 :3  value 22,60 :1  value 22,61 :4  value 22,62 :3
value 22,64 :2  value 22,66 :3  value 22,67 :3  value 22,68 :2  value 22,71 :3
value 22,72 :2  value 22,73 :1  value 22,75 :1  value 22,77 :1  value 22,78 :1
value 22,80 :2  value 22,81 :1  value 22,83 :1  value 22,84 :2  value 22,85 :2
value 22,86 :3  value 22,87 :1  value 22,88 :5  value 22,89 :2  value 22,90 :2
value 22,93 :1  value 22,94 :1  value 22,96 :2  value 22,98 :1  value 23,01 :1
value 23,02 :1  value 23,06 :1
```

ROI A7 :

Membro inferior direito:

```
Centro: {X=82,Y=94}
Minimo: 23,18
Maximo: 23,49
Mediana: 23,32
Media: 23,32
Desvio Padrao: 1,50
Skewness: -2,135414916867E-05
Kurtosis: -0,390049197464086
```

Pixeis:

```
23,19 23,21 23,21 23,21 23,24 23,27 23,30 23,22 23,28
23,21 23,18 23,23 23,18 23,23 23,27 23,32 23,29 23,27
23,25 23,27 23,23 23,22 23,33 23,32 23,32 23,31 23,30
23,30 23,25 23,32 23,30 23,32 23,34 23,35 23,35 23,33
23,30 23,29 23,30 23,29 23,32 23,35 23,32 23,34 23,32
23,30 23,31 23,35 23,36 23,37 23,34 23,35 23,38 23,36
23,30 23,34 23,37 23,38 23,37 23,38 23,36 23,37 23,39
23,43 23,37 23,37 23,38 23,40 23,38 23,38 23,39 23,39
23,49 23,38 23,41 23,38 23,38 23,41 23,42 23,42 23,38
```

Histograma:

```
value 23,18 :2  value 23,19 :1  value 23,21 :4  value 23,22 :2  value 23,23 :3
value 23,24 :1  value 23,25 :2  value 23,27 :4  value 23,28 :1  value 23,29 :3
value 23,30 :8  value 23,31 :2  value 23,32 :8  value 23,33 :2  value 23,34 :4
value 23,35 :5  value 23,36 :3  value 23,37 :6  value 23,38 :10  value 23,39 :3
value 23,40 :1  value 23,41 :2  value 23,42 :2  value 23,43 :1  value 23,49 :1
```

Membro inferior esquerdo:

Centro: {X=210,Y=92}  
 Minimo: 22,81  
 Maximo: 23,34  
 Mediana: 23,09  
 Media: 23,10  
 Desvio Padrao: 2,56  
 Skewness: -2,26553331926622E-05  
 Kurtosis: -0,115760159855899

Pixelis:

22,88	22,86	22,81	22,92	22,89	22,95	22,95	23,06	23,13
22,95	22,90	22,93	22,90	22,99	23,01	23,01	23,05	23,09
23,06	22,97	23,06	23,01	23,00	23,01	23,02	23,16	23,14
23,02	23,06	23,06	23,05	23,02	23,08	23,08	23,16	23,15
23,07	23,05	23,09	23,07	23,13	23,14	23,07	23,09	23,20
23,15	23,07	23,07	23,09	23,13	23,16	23,18	23,20	23,20
23,15	23,13	23,09	23,12	23,11	23,18	23,15	23,16	23,21
23,12	23,14	23,12	23,15	23,20	23,23	23,19	23,23	23,34
23,20	23,25	23,27	23,23	23,23	23,28	23,29	23,32	23,29

Histograma:

value 22,81 :1	value 22,86 :1	value 22,88 :1	value 22,89 :1	value 22,90 :2
value 22,92 :1	value 22,93 :1	value 22,95 :3	value 22,97 :1	value 22,99 :1
value 23,00 :1	value 23,01 :4	value 23,02 :3	value 23,05 :3	value 23,06 :5
value 23,07 :5	value 23,08 :2	value 23,09 :5	value 23,11 :1	value 23,12 :3
value 23,13 :4	value 23,14 :3	value 23,15 :5	value 23,16 :4	value 23,18 :2
value 23,19 :1	value 23,20 :5	value 23,21 :1	value 23,23 :4	value 23,25 :1
value 23,27 :1	value 23,28 :1	value 23,29 :2	value 23,32 :1	value 23,34 :1

ROI A8 :

Membro inferior direito:

Centro: {X=52,Y=88}  
 Minimo: 22,92  
 Maximo: 23,45  
 Mediana: 23,23  
 Media: 23,21  
 Desvio Padrao: 2,56  
 Skewness: -5,13756825991456E-05  
 Kurtosis: -0,125129113554222

Pixelis:

```

23,01 23,01 23,01 22,94 23,08 23,08 23,17 23,23 23,22
23,00 22,92 23,09 23,09 22,98 23,07 23,16 23,13 23,22
23,03 23,07 23,10 23,09 23,16 23,10 23,23 23,23 23,20
23,16 23,15 23,11 23,15 23,15 23,22 23,23 23,27 23,25
23,20 23,21 23,21 23,20 23,23 23,31 23,25 23,32 23,31
23,20 23,23 23,25 23,27 23,26 23,28 23,29 23,30 23,31
23,23 23,18 23,30 23,26 23,25 23,31 23,34 23,33 23,33
23,28 23,26 23,28 23,27 23,26 23,34 23,34 23,37 23,36
23,34 23,27 23,26 23,29 23,32 23,33 23,37 23,38 23,45

```

Histograma:

```

value 22,92 :1  value 22,94 :1  value 22,98 :1  value 23,00 :1  value 23,01 :3
value 23,03 :1  value 23,07 :2  value 23,08 :2  value 23,09 :3  value 23,10 :2
value 23,11 :1  value 23,13 :1  value 23,15 :3  value 23,16 :3  value 23,17 :1
value 23,18 :1  value 23,20 :4  value 23,21 :2  value 23,22 :3  value 23,23 :7
value 23,25 :4  value 23,26 :5  value 23,27 :4  value 23,28 :3  value 23,29 :2
value 23,30 :2  value 23,31 :4  value 23,32 :2  value 23,33 :3  value 23,34 :4
value 23,36 :1  value 23,37 :2  value 23,38 :1  value 23,45 :1

```

Membro inferior esquerdo:

```

Centro: {X=238,Y=87}
Minimo: 23,20
Maximo: 23,70
Mediana: 23,45
Media: 23,45
Desvio Padrao: 2,91
Skewness: -3,2214763795029E-06
Kurtosis: -0,895355173704365

```

Pixeis:

```

23,30 23,32 23,29 23,36 23,24 23,22 23,24 23,24 23,20
23,44 23,38 23,38 23,38 23,28 23,31 23,33 23,30 23,21
23,42 23,39 23,46 23,42 23,41 23,37 23,33 23,26 23,33
23,44 23,46 23,47 23,49 23,43 23,40 23,32 23,33 23,31
23,55 23,49 23,45 23,45 23,45 23,44 23,41 23,39 23,33
23,57 23,56 23,53 23,52 23,43 23,48 23,46 23,36 23,37
23,55 23,58 23,57 23,58 23,55 23,51 23,55 23,50 23,42
23,55 23,60 23,59 23,63 23,70 23,57 23,55 23,57 23,55
23,68 23,64 23,63 23,65 23,61 23,62 23,67 23,64 23,54

```

Histograma:

```

value 23,20 :1  value 23,21 :1  value 23,22 :1  value 23,24 :3  value 23,26 :1
value 23,28 :1  value 23,29 :1  value 23,30 :2  value 23,31 :2  value 23,32 :2
value 23,33 :5  value 23,36 :2  value 23,37 :2  value 23,38 :3  value 23,39 :2

```



```

value 23,40 :1  value 23,41 :2  value 23,42 :3  value 23,43 :2  value 23,44 :3
value 23,45 :3  value 23,46 :3  value 23,47 :1  value 23,48 :1  value 23,49 :2
value 23,50 :1  value 23,51 :1  value 23,52 :1  value 23,53 :1  value 23,54 :1
value 23,55 :7  value 23,56 :1  value 23,57 :4  value 23,58 :2  value 23,59 :1
value 23,60 :1  value 23,61 :1  value 23,62 :1  value 23,63 :2  value 23,64 :2
value 23,65 :1  value 23,67 :1  value 23,68 :1  value 23,70 :1

```

ROI A9 :

Membro inferior direito:

```

Centro: {X=23,Y=109}
Minimo: 23,25
Maximo: 23,70
Mediana: 23,42
Media: 23,43
Desvio Padrao: 1,81
Skewness: 3,72963585561544E-05
Kurtosis: 0,890274887759364

```

Pixeis:

```

23,29  23,34  23,36  23,40  23,37  23,40  23,39  23,39  23,40
23,38  23,35  23,36  23,36  23,40  23,42  23,42  23,42  23,42
23,39  23,38  23,38  23,42  23,40  23,44  23,42  23,45  23,48
23,42  23,41  23,39  23,40  23,43  23,43  23,47  23,45  23,53
23,37  23,38  23,41  23,41  23,44  23,45  23,48  23,51  23,55
23,25  23,36  23,38  23,46  23,46  23,47  23,52  23,52  23,52
23,31  23,35  23,40  23,41  23,47  23,50  23,49  23,56  23,58
23,33  23,34  23,37  23,38  23,46  23,52  23,52  23,52  23,53
23,28  23,26  23,38  23,34  23,50  23,49  23,55  23,58  23,70

```

Histograma:

```

value 23,25 :1  value 23,26 :1  value 23,28 :1  value 23,29 :1  value 23,31 :1
value 23,33 :1  value 23,34 :3  value 23,35 :2  value 23,36 :4  value 23,37 :3
value 23,38 :7  value 23,39 :4  value 23,40 :7  value 23,41 :4  value 23,42 :7
value 23,43 :2  value 23,44 :2  value 23,45 :3  value 23,46 :3  value 23,47 :3
value 23,48 :2  value 23,49 :2  value 23,50 :2  value 23,51 :1  value 23,52 :6
value 23,53 :2  value 23,55 :2  value 23,56 :1  value 23,58 :2  value 23,70 :1

```

Membro inferior esquerdo:

```

Centro: {X=266,Y=109}
Minimo: 23,50
Maximo: 24,01

```

Mediana: 23,73  
 Media: 23,74  
 Desvio Padrao: 3,32  
 Skewness: 7,29987890825661E-06  
 Kurtosis: -1,26862605535684

Pixeis:

```
23,77 23,71 23,74 23,73 23,69 23,61 23,58 23,55 23,54
23,85 23,77 23,77 23,73 23,73 23,60 23,55 23,53 23,50
23,79 23,88 23,80 23,74 23,72 23,69 23,67 23,60 23,51
23,87 23,90 23,88 23,77 23,72 23,63 23,65 23,57 23,52
23,91 23,89 23,86 23,84 23,71 23,62 23,65 23,58 23,54
23,96 23,94 23,86 23,89 23,81 23,65 23,63 23,62 23,58
23,95 23,95 23,96 23,88 23,89 23,88 23,65 23,61 23,58
23,97 23,95 23,93 23,93 23,82 23,79 23,64 23,63 23,56
24,01 23,97 23,95 23,95 23,77 23,76 23,71 23,59 23,60
```

Histograma:

```
value 23,50 :1 value 23,51 :1 value 23,52 :1 value 23,53 :1 value 23,54 :2
value 23,55 :2 value 23,56 :1 value 23,57 :1 value 23,58 :4 value 23,59 :1
value 23,60 :3 value 23,61 :2 value 23,62 :2 value 23,63 :3 value 23,64 :1
value 23,65 :4 value 23,67 :1 value 23,69 :2 value 23,71 :3 value 23,72 :2
value 23,73 :3 value 23,74 :2 value 23,76 :1 value 23,77 :5 value 23,79 :2
value 23,80 :1 value 23,81 :1 value 23,82 :1 value 23,84 :1 value 23,85 :1
value 23,86 :2 value 23,87 :1 value 23,88 :4 value 23,89 :3 value 23,90 :1
value 23,91 :1 value 23,93 :2 value 23,94 :1 value 23,95 :5 value 23,96 :2
value 23,97 :2 value 24,01 :1
```

ROI A10 :

Membro inferior direito:

Centro: {X=53,Y=146}  
 Minimo: 25,83  
 Maximo: 26,27  
 Mediana: 26,11  
 Media: 26,09  
 Desvio Padrao: 2,47  
 Skewness: -4,81170784210046E-05  
 Kurtosis: -0,377884340494205

Pixeis:

```
25,85 25,89 25,94 26,04 26,06 26,15 26,13 26,03 26,11
25,83 26,02 25,98 26,04 26,10 26,10 26,11 26,16 26,09
```

```

25,86 26,05 25,96 26,02 26,09 26,11 26,11 26,15 26,12
25,93 25,94 26,10 26,04 26,12 26,10 26,15 26,18 26,15
25,96 25,98 26,04 26,11 26,13 26,15 26,18 26,20 26,19
25,92 25,96 26,09 26,09 26,15 26,18 26,20 26,21 26,21
25,89 25,99 26,06 26,13 26,17 26,18 26,23 26,20 26,21
25,87 26,04 26,07 26,15 26,21 26,21 26,21 26,22 26,23
25,94 26,07 26,05 26,05 26,14 26,18 26,21 26,24 26,27

```

Histograma:

```

value 25,83 :1 value 25,85 :1 value 25,86 :1 value 25,87 :1 value 25,89 :2
value 25,92 :1 value 25,93 :1 value 25,94 :3 value 25,96 :3 value 25,98 :2
value 25,99 :1 value 26,02 :2 value 26,03 :1 value 26,04 :5 value 26,05 :3
value 26,06 :2 value 26,07 :2 value 26,09 :4 value 26,10 :4 value 26,11 :5
value 26,12 :2 value 26,13 :3 value 26,14 :1 value 26,15 :7 value 26,16 :1
value 26,17 :1 value 26,18 :5 value 26,19 :1 value 26,20 :3 value 26,21 :7
value 26,22 :1 value 26,23 :2 value 26,24 :1 value 26,27 :1

```

Membro inferior esquerdo:

```

Centro: {X=240,Y=143}
Minimo: 25,37
Maximo: 25,54
Mediana: 25,46
Media: 25,45
Desvio Padrao: ,73
Skewness: 1,92639129776609E-05
Kurtosis: 0,19111038093747

```

Pixeis:

```

25,46 25,46 25,48 25,45 25,46 25,46 25,42 25,42 25,40
25,45 25,43 25,46 25,46 25,47 25,45 25,44 25,41 25,41
25,42 25,47 25,48 25,45 25,48 25,54 25,42 25,42 25,40
25,45 25,49 25,46 25,46 25,47 25,53 25,44 25,41 25,37
25,46 25,47 25,46 25,47 25,46 25,44 25,42 25,43 25,42
25,43 25,44 25,46 25,48 25,43 25,44 25,44 25,42 25,41
25,42 25,48 25,41 25,45 25,44 25,50 25,42 25,46 25,42
25,46 25,45 25,49 25,46 25,50 25,50 25,49 25,48 25,46
25,45 25,50 25,47 25,50 25,50 25,47 25,41 25,47 25,46

```

Histograma:

```

value 25,37 :1 value 25,40 :2 value 25,41 :6 value 25,42 :11 value 25,43 :4
value 25,44 :7 value 25,45 :8 value 25,46 :17 value 25,47 :8 value 25,48 :6
value 25,49 :3 value 25,50 :6 value 25,53 :1
value 25,54 :1

```

ROI A11 :

Membro inferior direito:

Centro: {X=37,Y=174}

Minimo: 24,40

Maximo: 24,92

Mediana: 24,59

Media: 24,59

Desvio Padrao: 3,19

Skewness: 3,72259642504829E-05

Kurtosis: -0,824661676168121

Pixeis:

24,44	24,44	24,58	24,67	24,64	24,73	24,76	24,92	24,88
24,44	24,47	24,45	24,51	24,63	24,69	24,73	24,79	24,86
24,44	24,47	24,50	24,63	24,63	24,72	24,73	24,87	24,85
24,40	24,44	24,60	24,61	24,50	24,67	24,74	24,81	24,81
24,46	24,43	24,48	24,60	24,49	24,65	24,73	24,76	24,83
24,42	24,44	24,46	24,62	24,57	24,60	24,63	24,75	24,73
24,44	24,44	24,46	24,55	24,54	24,57	24,59	24,69	24,72
24,41	24,44	24,50	24,45	24,50	24,61	24,58	24,64	24,69
24,44	24,43	24,46	24,50	24,46	24,53	24,56	24,60	24,67

Histograma:

value 24,40 :1	value 24,41 :1	value 24,42 :1	value 24,43 :2	value 24,44 :10
value 24,45 :2	value 24,46 :5	value 24,47 :2	value 24,48 :1	value 24,49 :1
value 24,50 :5	value 24,51 :1	value 24,53 :1	value 24,54 :1	value 24,55 :1
value 24,56 :1	value 24,57 :2	value 24,58 :2	value 24,59 :1	value 24,60 :4
value 24,61 :2	value 24,62 :1	value 24,63 :4	value 24,64 :2	value 24,65 :1
value 24,67 :3	value 24,69 :3	value 24,72 :2	value 24,73 :5	value 24,74 :1
value 24,75 :1	value 24,76 :2	value 24,79 :1	value 24,81 :2	value 24,83 :1
value 24,85 :1	value 24,86 :1	value 24,87 :1	value 24,88 :1	value 24,92 :1

Membro inferior esquerdo:

Centro: {X=258,Y=172}

Minimo: 23,96

Maximo: 24,46

Mediana: 24,14

Media: 24,16

Desvio Padrao: 2,60

Skewness: 3,19496601765374E-05

Kurtosis: -0,236425425611391

Pixelis:

```

24,46 24,44 24,34 24,28 24,23 24,27 24,23 24,22 24,26
24,40 24,28 24,26 24,34 24,25 24,24 24,24 24,24 24,26
24,27 24,27 24,33 24,22 24,26 24,25 24,21 24,24 24,23
24,33 24,14 24,24 24,22 24,15 24,17 24,08 24,08 24,12
24,26 24,12 24,13 24,15 24,16 24,18 24,18 24,10 24,15
24,16 24,12 24,15 24,12 24,14 24,04 24,14 24,10 24,08
24,11 24,11 24,07 24,08 24,05 24,02 24,10 24,10 24,10
24,06 24,05 24,06 24,05 23,97 24,07 24,00 24,03 23,96
24,13 24,06 24,05 24,01 23,99 24,00 23,99 23,96 23,98

```

Histograma:

```

value 23,96 :2 value 23,97 :1 value 23,98 :1 value 23,99 :2 value 24,00 :2
value 24,01 :1 value 24,02 :1 value 24,03 :1 value 24,04 :1 value 24,05 :4
value 24,06 :3 value 24,07 :2 value 24,08 :4 value 24,10 :5 value 24,11 :2
value 24,12 :4 value 24,13 :2 value 24,14 :3 value 24,15 :4 value 24,16 :2
value 24,17 :1 value 24,18 :2 value 24,21 :1 value 24,22 :3 value 24,23 :3
value 24,24 :5 value 24,25 :2 value 24,26 :5 value 24,27 :3 value 24,28 :2
value 24,33 :2 value 24,34 :2 value 24,40 :1 value 24,44 :1 value 24,46 :1

```

ROI A12 :

Membro inferior direito:

```

Centro: {X=61,Y=228}
Minimo: 22,31
Maximo: 22,81
Mediana: 22,50
Media: 22,51
Desvio Padrao: 2,52
Skewness: 4,68834454650363E-05
Kurtosis: -0,460202123140375

```

Pixelis:

```

22,64 22,66 22,70 22,77 22,81 22,64 22,66 22,73 22,67
22,64 22,61 22,60 22,64 22,59 22,65 22,68 22,61 22,60
22,52 22,54 22,52 22,54 22,64 22,62 22,64 22,58 22,61
22,51 22,51 22,44 22,52 22,62 22,49 22,55 22,54 22,58
22,43 22,43 22,45 22,42 22,52 22,50 22,42 22,52 22,54
22,40 22,42 22,41 22,44 22,42 22,44 22,52 22,50 22,54
22,40 22,44 22,40 22,40 22,41 22,43 22,48 22,39 22,43
22,39 22,37 22,38 22,39 22,43 22,41 22,40 22,46 22,44
22,32 22,31 22,36 22,36 22,41 22,39 22,43 22,49 22,42

```

Histograma:

```
value 22,31 :1  value 22,32 :1  value 22,36 :2  value 22,37 :1  value 22,38 :1
value 22,39 :4  value 22,40 :5  value 22,41 :4  value 22,42 :5  value 22,43 :6
value 22,44 :5  value 22,45 :1  value 22,46 :1  value 22,48 :1  value 22,49 :2
value 22,50 :2  value 22,51 :2  value 22,52 :6  value 22,54 :5  value 22,55 :1
value 22,58 :2  value 22,59 :1  value 22,60 :2  value 22,61 :3  value 22,62 :2
value 22,64 :6  value 22,65 :1  value 22,66 :2  value 22,67 :1  value 22,68 :1
value 22,70 :1  value 22,73 :1  value 22,77 :1  value 22,81 :1
```

Membro inferior esquerdo:

```
Centro: {X=241,Y=222}
Minimo: 22,12
Maximo: 22,46
Mediana: 22,28
Media: 22,29
Desvio Padrao: 2,03
Skewness: 1,53232685483012E-05
Kurtosis: -0,978439182079484
```

Pixeis:

```
22,41  22,46  22,41  22,46  22,43  22,44  22,40  22,41  22,41
22,41  22,40  22,42  22,36  22,37  22,41  22,36  22,32  22,37
22,45  22,28  22,31  22,34  22,36  22,34  22,33  22,36  22,41
22,26  22,26  22,26  22,37  22,33  22,33  22,36  22,32  22,31
22,27  22,28  22,25  22,28  22,28  22,28  22,31  22,28  22,30
22,24  22,22  22,23  22,25  22,29  22,29  22,28  22,23  22,22
22,25  22,23  22,23  22,24  22,24  22,21  22,22  22,24  22,23
22,24  22,24  22,18  22,20  22,17  22,17  22,21  22,16  22,17
22,23  22,12  22,15  22,17  22,16  22,17  22,15  22,15  22,15
```

Histograma:

```
value 22,12 :1  value 22,15 :4  value 22,16 :2  value 22,17 :5  value 22,18 :1
value 22,20 :1  value 22,21 :2  value 22,22 :3  value 22,23 :6  value 22,24 :6
value 22,25 :3  value 22,26 :3  value 22,27 :1  value 22,28 :7  value 22,29 :2
value 22,30 :1  value 22,31 :3  value 22,32 :2  value 22,33 :3  value 22,34 :2
value 22,36 :5  value 22,37 :3  value 22,40 :2  value 22,41 :7  value 22,42 :1
value 22,43 :1  value 22,44 :1  value 22,45 :1  value 22,46 :2
```

## D.2 Em graus radiométricos

Radiometric Values:

ROI A1 :

Membro inferior direito:

Centro: {X=68,Y=35}

Minimo: 18094

Maximo: 18234

Mediana: 18160

Media: 18158

Desvio Padrao: 37,13775

Skewness: 0,15745389808304

Kurtosis: -0,972983788759311

Pixeis:

```
18183 18194 18199 18188 18192 18208 18228 18230 18234
18151 18182 18169 18181 18200 18194 18219 18219 18215
18152 18168 18159 18193 18174 18202 18208 18203 18206
18161 18164 18180 18175 18168 18167 18208 18184 18211
18155 18175 18143 18158 18163 18160 18195 18166 18169
18154 18148 18140 18156 18153 18143 18165 18141 18161
18122 18119 18107 18134 18116 18135 18127 18118 18148
18126 18120 18109 18114 18125 18114 18105 18116 18130
18107 18128 18117 18096 18094 18099 18104 18104 18111
```

Histograma:

```
value 18094 :1 value 18096 :1 value 18099 :1 value 18104 :2 value 18105 :1 value 18107 :2
value 18109 :1 value 18111 :1
value 18114 :2 value 18116 :2 value 18117 :1 value 18118 :1 value 18119 :1 value 18120 :1
value 18122 :1 value 18125 :1
value 18126 :1 value 18127 :1 value 18128 :1 value 18130 :1 value 18134 :1 value 18135 :1
value 18140 :1 value 18141 :1
value 18143 :2 value 18148 :2 value 18151 :1 value 18152 :1 value 18153 :1 value 18154 :1
value 18155 :1 value 18156 :1
value 18158 :1 value 18159 :1 value 18160 :1 value 18161 :2 value 18163 :1 value 18164 :1
value 18165 :1 value 18166 :1
value 18167 :1 value 18168 :2 value 18169 :2 value 18174 :1 value 18175 :2 value 18180 :1
value 18181 :1 value 18182 :1
value 18183 :1 value 18184 :1 value 18188 :1 value 18192 :1 value 18193 :1 value 18194 :2
value 18195 :1 value 18199 :1
value 18200 :1 value 18202 :1 value 18203 :1 value 18206 :1 value 18208 :3 value 18211 :1
value 18215 :1 value 18219 :2
value 18228 :1 value 18230 :1 value 18234 :1
```

Membro inferior esquerdo:

Centro: {X=212,Y=31}  
 Minimo E: 18162  
 Maximo E: 18305  
 Mediana: 18229  
 Media: 18228  
 Media: 18228  
 Desvio Padrao: 36,2155  
 Skewness: -0,0409091946217508  
 Kurtosis: -0,974160936043363

Pixeis:

18305	18284	18293	18276	18280	18267	18274	18266	18261
18289	18275	18273	18260	18269	18275	18272	18249	18249
18261	18255	18258	18269	18268	18262	18235	18246	18229
18256	18254	18260	18249	18239	18237	18239	18238	18227
18221	18216	18248	18235	18219	18233	18230	18232	18224
18203	18222	18234	18215	18200	18196	18224	18218	18202
18211	18221	18212	18202	18197	18210	18216	18191	18185
18188	18196	18214	18193	18175	18179	18173	18174	18190
18171	18163	18169	18162	18178	18178	18206	18175	18169

Histograma:

value 18162 :1	value 18163 :1	value 18169 :2	value 18171 :1	value 18173 :1	value 18174 :1
value 18175 :2	value 18178 :2	value 18179 :1	value 18185 :1	value 18188 :1	value 18190 :1
value 18191 :1	value 18193 :1	value 18196 :2	value 18197 :1	value 18200 :1	value 18202 :2
value 18203 :1	value 18206 :1	value 18210 :1	value 18211 :1	value 18212 :1	value 18214 :1
value 18215 :1	value 18216 :2	value 18218 :1	value 18219 :1	value 18221 :2	value 18222 :1
value 18224 :2	value 18227 :1	value 18229 :1	value 18230 :1	value 18232 :1	value 18233 :1
value 18234 :1	value 18235 :2	value 18237 :1	value 18238 :1	value 18239 :2	value 18246 :1
value 18248 :1	value 18249 :3	value 18254 :1	value 18255 :1	value 18256 :1	value 18258 :1
value 18260 :2	value 18261 :2	value 18262 :1	value 18266 :1	value 18267 :1	value 18268 :1
value 18269 :2	value 18272 :1	value 18273 :1	value 18274 :1	value 18275 :2	value 18276 :1
value 18280 :1	value 18284 :1	value 18289 :1	value 18293 :1	value 18305 :1	

ROI A2 :

Membro inferior direito:

Centro: {X=43,Y=45}  
 Minimo: 18099  
 Maximo: 18173  
 Mediana: 18121  
 Media: 18122



Desvio Padrao: 13,48379  
 Skewness: 1,21087416296799  
 Kurtosis: 2,0902516475566

Pixeis:

```
18127 18154 18133 18141 18129 18139 18138 18135 18154
18146 18135 18133 18134 18131 18118 18115 18122 18105
18099 18135 18128 18125 18133 18110 18117 18107 18111
18114 18133 18133 18130 18128 18109 18114 18127 18109
18126 18122 18127 18117 18131 18105 18109 18110 18114
18100 18124 18114 18119 18117 18115 18113 18110 18108
18129 18119 18118 18119 18121 18105 18108 18111 18109
18110 18126 18124 18115 18114 18117 18122 18115 18135
18119 18134 18129 18115 18128 18121 18130 18159 18173
```

Histograma:

```
value 18099 :1 value 18100 :1 value 18105 :3 value 18107 :1 value 18108 :2 value 18109 :4
value 18110 :4 value 18111 :2
value 18113 :1 value 18114 :5 value 18115 :5 value 18117 :4 value 18118 :2 value 18119 :4
value 18121 :2 value 18122 :3
value 18124 :2 value 18125 :1 value 18126 :2 value 18127 :3 value 18128 :3 value 18129 :3
value 18130 :2 value 18131 :2
value 18133 :5 value 18134 :2 value 18135 :4 value 18138 :1 value 18139 :1 value 18141 :1
value 18146 :1 value 18154 :2
value 18159 :1 value 18173 :1
```

Membro inferior esquerdo:

Centro: {X=241,Y=38}  
 Minimo E: 18121  
 Maximo E: 18198  
 Mediana: 18151  
 Media: 18152  
 Media: 18152  
 Desvio Padrao: 11,70043  
 Skewness: 1,46914229432343  
 Kurtosis: 3,58084401167683

Pixeis:

```
18179 18165 18158 18178 18145 18175 18172 18182 18198
18156 18143 18153 18157 18151 18149 18156 18160 18185
18143 18153 18144 18154 18166 18150 18147 18158 18159
18139 18144 18145 18152 18152 18146 18152 18157 18156
18141 18141 18121 18153 18145 18144 18147 18159 18154
18144 18142 18145 18148 18145 18146 18144 18138 18155
18149 18144 18146 18153 18151 18149 18151 18137 18162
```

```
18145 18149 18146 18150 18153 18155 18152 18149 18172
18149 18150 18151 18155 18148 18149 18141 18158 18161
```

Histograma:

```
value 18121 :1 value 18137 :1 value 18138 :1 value 18139 :1 value 18141 :3 value 18142 :1
value 18143 :2 value 18144 :6 value 18145 :6 value 18146 :4 value 18147 :2 value 18148 :2
value 18149 :7 value 18150 :3 value 18151 :4 value 18152 :4 value 18153 :5 value 18154 :2
value 18155 :3 value 18156 :3 value 18157 :2 value 18158 :3 value 18159 :2 value 18160 :1
value 18161 :1 value 18162 :1 value 18165 :1 value 18166 :1 value 18172 :2 value 18175 :1
value 18178 :1 value 18179 :1 value 18182 :1 value 18185 :1 value 18198 :1
```

ROI A3 :

Membro inferior direito:

```
Centro: {X=34,Y=53}
Minimo: 18119
Maximo: 18514
Mediana: 18139
Media: 18149
Desvio Padrao: 50,3499
Skewness: 5,42604174345008
Kurtosis: 35,8794070084952
```

Pixeis:

```
18514 18315 18223 18178 18194 18175 18175 18148 18141
18213 18212 18208 18166 18168 18148 18146 18140 18142
18169 18151 18150 18144 18152 18133 18140 18122 18141
18149 18157 18148 18142 18143 18119 18121 18120 18140
18132 18152 18143 18141 18139 18126 18137 18119 18137
18135 18141 18138 18123 18133 18126 18124 18129 18120
18131 18146 18130 18125 18139 18130 18132 18121 18132
18122 18137 18128 18124 18139 18127 18136 18134 18147
18125 18123 18132 18120 18139 18128 18143 18123 18143
```

Histograma:

```
value 18119 :2 value 18120 :3 value 18121 :2 value 18122 :2 value 18123 :3 value 18124 :2
value 18125 :2 value 18126 :2
value 18127 :1 value 18128 :2 value 18129 :1 value 18130 :2 value 18131 :1 value 18132 :4
value 18133 :2 value 18134 :1
value 18135 :1 value 18136 :1 value 18137 :3 value 18138 :1 value 18139 :4 value 18140 :3
value 18141 :4 value 18142 :2
value 18143 :4 value 18144 :1 value 18146 :2 value 18147 :1 value 18148 :3 value 18149 :1
value 18150 :1 value 18151 :1
```

```

value 18152 :2  value 18157 :1  value 18166 :1  value 18168 :1  value 18169 :1  value 18175 :2
value 18178 :1  value 18194 :1
value 18208 :1  value 18212 :1  value 18213 :1  value 18223 :1  value 18315 :1  value 18514 :1

```

Membro inferior esquerdo:

```

Centro: {X=249,Y=46}
Minimo E: 18158
Maximo E: 18879
Mediana: 18176
Media: 18220
Media: 18220
Desvio Padrao: 123,2982
Skewness: 3,53701352077332
Kurtosis: 13,5136590530928

```

Pixeis:

```

18161  18158  18363  18654  18455  18392  18492  18691  18879
18164  18174  18318  18193  18239  18231  18243  18313  18422
18194  18187  18177  18185  18194  18203  18227  18239  18239
18183  18177  18179  18175  18177  18197  18192  18192  18211
18173  18175  18164  18173  18172  18175  18178  18185  18192
18173  18172  18167  18166  18178  18180  18166  18172  18170
18170  18168  18179  18168  18176  18174  18172  18178  18170
18170  18174  18169  18171  18174  18175  18178  18170  18169
18179  18172  18170  18174  18170  18168  18173  18167  18166

```

Histograma:

```

value 18158 :1  value 18161 :1  value 18164 :2  value 18166 :3  value 18167 :2  value 18168 :3
value 18169 :2  value 18170 :7  value 18171 :1  value 18172 :5  value 18173 :4  value 18174 :5
value 18175 :4  value 18176 :1  value 18177 :3  value 18178 :4  value 18179 :3  value 18180 :1
value 18183 :1  value 18185 :2  value 18187 :1  value 18192 :3  value 18193 :1  value 18194 :2
value 18197 :1  value 18203 :1  value 18211 :1  value 18227 :1  value 18231 :1  value 18239 :3
value 18243 :1  value 18313 :1  value 18318 :1  value 18363 :1  value 18392 :1  value 18422 :1
value 18455 :1  value 18492 :1  value 18654 :1  value 18691 :1  value 18879 :1

```

ROI A4 :

Membro inferior direito:

```

Centro: {X=23,Y=63}
Minimo: 18159
Maximo: 18832
Mediana: 18189
Media: 18236
Desvio Padrao: 145,0855

```

Skewness: 3,03889083132075

Kurtosis: 8,39844221685265

Pixeis:

```
18832 18796 18622 18358 18234 18220 18207 18201 18177
18759 18611 18343 18205 18196 18192 18190 18169 18171
18666 18348 18202 18196 18189 18171 18169 18168 18161
18449 18194 18183 18174 18175 18177 18187 18172 18159
18262 18195 18181 18177 18184 18189 18181 18178 18179
18208 18172 18171 18177 18175 18177 18181 18175 18190
18173 18174 18182 18183 18185 18190 18180 18186 18186
18179 18188 18189 18188 18195 18203 18199 18198 18224
18191 18187 18190 18193 18199 18192 18202 18200 18199
```

Histograma:

```
value 18159 :1 value 18161 :1 value 18168 :1 value 18169 :2 value 18171 :3 value 18172 :2
value 18173 :1 value 18174 :2
value 18175 :3 value 18177 :5 value 18178 :1 value 18179 :2 value 18180 :1 value 18181 :3
value 18182 :1 value 18183 :2
value 18184 :1 value 18185 :1 value 18186 :2 value 18187 :2 value 18188 :2 value 18189 :3
value 18190 :4 value 18191 :1
value 18192 :2 value 18193 :1 value 18194 :1 value 18195 :2 value 18196 :2 value 18198 :1
value 18199 :3 value 18200 :1
value 18201 :1 value 18202 :2 value 18203 :1 value 18205 :1 value 18207 :1 value 18208 :1
value 18220 :1 value 18224 :1
value 18234 :1 value 18262 :1 value 18343 :1 value 18348 :1 value 18358 :1 value 18449 :1
value 18611 :1 value 18622 :1
value 18666 :1 value 18759 :1 value 18796 :1 value 18832 :1
```

Membro inferior esquerdo:

Centro: {X=259,Y=54}

Minimo E: 18170

Maximo E: 18698

Mediana: 18223

Media: 18234

Media: 18234

Desvio Padrao: 62,80127

Skewness: 5,54813192702795

Kurtosis: 38,2870098102543

Pixeis:

```
18171 18185 18286 18262 18261 18265 18308 18419 18698
18170 18191 18210 18208 18211 18257 18264 18304 18344
18185 18201 18205 18212 18209 18211 18231 18252 18250
18212 18212 18208 18207 18207 18217 18231 18235 18259
```

```

18205 18218 18206 18206 18219 18215 18230 18229 18234
18223 18206 18211 18205 18219 18220 18225 18225 18226
18215 18230 18214 18220 18216 18220 18226 18226 18229
18237 18223 18243 18237 18228 18213 18224 18224 18223
18246 18246 18243 18232 18224 18225 18230 18212 18186

```

Histograma:

```

value 18170 :1 value 18171 :1 value 18185 :2 value 18186 :1 value 18191 :1 value 18201 :1
value 18205 :3 value 18206 :3 value 18207 :2 value 18208 :2 value 18209 :1 value 18210 :1
value 18211 :3 value 18212 :4 value 18213 :1 value 18214 :1 value 18215 :2 value 18216 :1
value 18217 :1 value 18218 :1 value 18219 :2 value 18220 :3 value 18223 :3 value 18224 :3
value 18225 :3 value 18226 :3 value 18228 :1 value 18229 :2 value 18230 :3 value 18231 :2
value 18232 :1 value 18234 :1 value 18235 :1 value 18237 :2 value 18243 :2 value 18246 :2
value 18250 :1 value 18252 :1 value 18257 :1 value 18259 :1 value 18261 :1 value 18262 :1
value 18264 :1 value 18265 :1 value 18286 :1 value 18304 :1 value 18308 :1 value 18344 :1
value 18419 :1 value 18698 :1

```

ROI A5 :

Membro inferior direito:

Centro: {X=14,Y=71}

Mínimo: 18144

Máximo: 18811

Mediana: 18213

Media: 18310

Desvio Padrao: 198,8039

Skewness: 1,4813850248637

Kurtosis: 0,784301747717453

Pixeis:

```

18811 18803 18720 18537 18326 18308 18257 18245 18196
18809 18781 18563 18322 18252 18252 18203 18198 18196
18776 18693 18406 18249 18242 18225 18200 18197 18195
18766 18578 18321 18236 18205 18218 18196 18172 18187
18724 18476 18249 18233 18190 18214 18196 18181 18177
18640 18377 18235 18216 18175 18188 18176 18168 18178
18577 18328 18213 18203 18170 18194 18161 18144 18163
18566 18294 18200 18190 18163 18181 18160 18173 18156
18542 18275 18187 18193 18181 18171 18167 18156 18176

```

Histograma:

```

value 18144 :1 value 18156 :2 value 18160 :1 value 18161 :1 value 18163 :2 value 18167 :1
value 18168 :1 value 18170 :1

```

```

value 18171 :1 value 18172 :1 value 18173 :1 value 18175 :1 value 18176 :2 value 18177 :1
value 18178 :1 value 18181 :3
value 18187 :2 value 18188 :1 value 18190 :2 value 18193 :1 value 18194 :1 value 18195 :1
value 18196 :4 value 18197 :1
value 18198 :1 value 18200 :2 value 18203 :2 value 18205 :1 value 18213 :1 value 18214 :1
value 18216 :1 value 18218 :1
value 18225 :1 value 18233 :1 value 18235 :1 value 18236 :1 value 18242 :1 value 18245 :1
value 18249 :2 value 18252 :2
value 18257 :1 value 18275 :1 value 18294 :1 value 18308 :1 value 18321 :1 value 18322 :1
value 18326 :1 value 18328 :1
value 18377 :1 value 18406 :1 value 18476 :1 value 18537 :1 value 18542 :1 value 18563 :1
value 18566 :1 value 18577 :1
value 18578 :1 value 18640 :1 value 18693 :1 value 18720 :1 value 18724 :1 value 18766 :1
value 18776 :1 value 18781 :1
value 18803 :1 value 18809 :1 value 18811 :1

```

Membro inferior esquerdo:

Centro: {X=267,Y=62}

Minimo E: 18186

Maximo E: 18361

Mediana: 18224

Media: 18230

Media: 18230

Desvio Padrao: 26,89447

Skewness: 2,16133084878212

Kurtosis: 6,98002108560479

Pixeis:

```

18186 18222 18224 18220 18216 18252 18252 18279 18361
18233 18224 18213 18219 18220 18211 18227 18236 18267
18236 18228 18214 18217 18214 18189 18218 18225 18253
18238 18227 18221 18223 18216 18216 18214 18216 18226
18242 18228 18226 18219 18192 18201 18199 18220 18222
18257 18234 18222 18211 18208 18219 18215 18202 18224
18275 18227 18231 18229 18217 18210 18209 18215 18227
18294 18250 18256 18240 18230 18209 18223 18221 18223
18284 18296 18226 18302 18241 18236 18217 18226 18233

```

Histograma:

```

value 18186 :1 value 18189 :1 value 18192 :1 value 18199 :1 value 18201 :1 value 18202 :1
value 18208 :1 value 18209 :2 value 18210 :1 value 18211 :2 value 18213 :1 value 18214 :3
value 18215 :2 value 18216 :4 value 18217 :3 value 18218 :1 value 18219 :3 value 18220 :3
value 18221 :2 value 18222 :3 value 18223 :3 value 18224 :3 value 18225 :1 value 18226 :4
value 18227 :4 value 18228 :2 value 18229 :1 value 18230 :1 value 18231 :1 value 18233 :2
value 18234 :1 value 18236 :3 value 18238 :1 value 18240 :1 value 18241 :1 value 18242 :1
value 18250 :1 value 18252 :2 value 18253 :1 value 18256 :1 value 18257 :1 value 18267 :1

```

```
value 18275 :1 value 18279 :1 value 18284 :1 value 18294 :1 value 18296 :1 value 18302 :1
value 18361 :1
```

ROI A6 :

Membro inferior direito:

```
Centro: {X=41,Y=76}
Minimo: 18316
Maximo: 18414
Mediana: 18352
Media: 18357
Desvio Padrao: 24,74166
Skewness: 0,402346887658022
Kurtosis: -0,912771424070941
```

Pixeis:

```
18316 18324 18327 18327 18330 18338 18336 18344 18336
18323 18330 18333 18350 18328 18330 18335 18328 18343
18320 18328 18342 18345 18351 18341 18340 18348 18351
18322 18334 18324 18337 18347 18356 18372 18354 18358
18334 18355 18358 18367 18357 18359 18372 18374 18382
18340 18343 18347 18375 18380 18375 18394 18385 18385
18350 18349 18367 18375 18364 18386 18385 18391 18395
18340 18367 18360 18367 18386 18388 18392 18390 18407
18342 18352 18379 18385 18392 18388 18400 18414 18408
```

Histograma:

```
value 18316 :1 value 18320 :1 value 18322 :1 value 18323 :1 value 18324 :2 value 18327 :2
value 18328 :3 value 18330 :3
value 18333 :1 value 18334 :2 value 18335 :1 value 18336 :2 value 18337 :1 value 18338 :1
value 18340 :3 value 18341 :1
value 18342 :2 value 18343 :2 value 18344 :1 value 18345 :1 value 18347 :2 value 18348 :1
value 18349 :1 value 18350 :2
value 18351 :2 value 18352 :1 value 18354 :1 value 18355 :1 value 18356 :1 value 18357 :1
value 18358 :2 value 18359 :1
value 18360 :1 value 18364 :1 value 18367 :4 value 18372 :2 value 18374 :1 value 18375 :3
value 18379 :1 value 18380 :1
value 18382 :1 value 18385 :4 value 18386 :2 value 18388 :2 value 18390 :1 value 18391 :1
value 18392 :2 value 18394 :1
value 18395 :1 value 18400 :1 value 18407 :1 value 18408 :1 value 18414 :1
```

Membro inferior esquerdo:

```
Centro: {X=239,Y=74}
Minimo E: 18357
```

Maximo E: 18488  
 Mediana: 18410  
 Media: 18414  
 Media: 18414  
 Desvio Padrao: 35,5139  
 Skewness: 0,152705405958503  
 Kurtosis: -1,07477408634852

Pixeis:

```
18376 18358 18371 18361 18360 18359 18357 18381 18370
18390 18372 18377 18361 18359 18383 18364 18366 18376
18438 18373 18395 18381 18389 18383 18397 18396 18390
18408 18396 18410 18389 18404 18396 18403 18399 18390
18450 18417 18419 18419 18418 18408 18411 18400 18400
18448 18422 18435 18425 18417 18409 18407 18430 18411
18457 18452 18445 18444 18442 18431 18436 18410 18445
18478 18472 18447 18448 18452 18451 18465 18444 18452
18488 18480 18469 18454 18463 18469 18454 18452 18457
```

Histograma:

```
value 18357 :1 value 18358 :1 value 18359 :2 value 18360 :1 value 18361 :2 value 18364 :1
value 18366 :1 value 18370 :1 value 18371 :1 value 18372 :1 value 18373 :1 value 18376 :2
value 18377 :1 value 18381 :2 value 18383 :2 value 18389 :2 value 18390 :3 value 18395 :1
value 18396 :3 value 18397 :1 value 18399 :1 value 18400 :2 value 18403 :1 value 18404 :1
value 18407 :1 value 18408 :2 value 18409 :1 value 18410 :2 value 18411 :2 value 18417 :2
value 18418 :1 value 18419 :2 value 18422 :1 value 18425 :1 value 18430 :1 value 18431 :1
value 18435 :1 value 18436 :1 value 18438 :1 value 18442 :1 value 18444 :2 value 18445 :2
value 18447 :1 value 18448 :2 value 18450 :1 value 18451 :1 value 18452 :4 value 18454 :2
value 18457 :2 value 18463 :1 value 18465 :1 value 18469 :2 value 18472 :1 value 18478 :1
value 18480 :1 value 18488 :1
```

ROI A7 :

Membro inferior direito:

Centro: {X=82,Y=94}  
 Minimo: 18514  
 Maximo: 18576  
 Mediana: 18542  
 Media: 18542  
 Desvio Padrao: 13,40569  
 Skewness: -0,212789224280031  
 Kurtosis: -0,404264946313902

Pixeis:



```

18516 18519 18519 18520 18526 18532 18537 18521 18533
18519 18514 18523 18514 18523 18532 18541 18536 18532
18527 18532 18523 18522 18543 18542 18542 18540 18538
18538 18527 18541 18537 18541 18545 18548 18548 18543
18538 18535 18538 18535 18541 18548 18542 18546 18542
18537 18540 18548 18549 18552 18546 18548 18555 18549
18537 18546 18552 18553 18551 18554 18549 18551 18557
18565 18551 18552 18555 18558 18555 18555 18557 18556
18576 18553 18561 18553 18555 18561 18563 18563 18555

```

Histograma:

```

value 18514 :2  value 18516 :1  value 18519 :3  value 18520 :1  value 18521 :1  value 18522 :1
value 18523 :3  value 18526 :1
value 18527 :2  value 18532 :4  value 18533 :1  value 18535 :2  value 18536 :1  value 18537 :4
value 18538 :4  value 18540 :2
value 18541 :4  value 18542 :4  value 18543 :2  value 18545 :1  value 18546 :3  value 18548 :5
value 18549 :3  value 18551 :3
value 18552 :3  value 18553 :3  value 18554 :1  value 18555 :6  value 18556 :1  value 18557 :2
value 18558 :1  value 18561 :2
value 18563 :2  value 18565 :1  value 18576 :1

```

Membro inferior esquerdo:

```

Centro: {X=210,Y=92}
Minimo E: 18437
Maximo E: 18546
Mediana: 18495
Media: 18496
Media: 18496
Desvio Padrao: 22,86373
Skewness: -0,230884652714953
Kurtosis: -0,13078666041358

```

Pixeis:

```

18451 18447 18437 18461 18453 18466 18466 18488 18503
18466 18457 18462 18455 18475 18479 18478 18486 18495
18488 18471 18489 18479 18476 18479 18481 18510 18505
18481 18489 18489 18486 18481 18492 18493 18510 18508
18491 18486 18494 18491 18502 18504 18490 18494 18517
18507 18491 18491 18494 18502 18509 18513 18518 18517
18506 18502 18495 18500 18498 18513 18506 18509 18519
18501 18505 18501 18508 18518 18524 18515 18523 18546
18517 18527 18531 18524 18523 18533 18535 18541 18535

```

Histograma:

```

value 18437 :1  value 18447 :1  value 18451 :1  value 18453 :1  value 18455 :1  value 18457 :1

```

```

value 18461 :1  value 18462 :1  value 18466 :3  value 18471 :1  value 18475 :1  value 18476 :1
value 18478 :1  value 18479 :3  value 18481 :3  value 18486 :3  value 18488 :2  value 18489 :3
value 18490 :1  value 18491 :4  value 18492 :1  value 18493 :1  value 18494 :3  value 18495 :2
value 18498 :1  value 18500 :1  value 18501 :2  value 18502 :3  value 18503 :1  value 18504 :1
value 18505 :2  value 18506 :2  value 18507 :1  value 18508 :2  value 18509 :2  value 18510 :2
value 18513 :2  value 18515 :1  value 18517 :3  value 18518 :2  value 18519 :1  value 18523 :2
value 18524 :2  value 18527 :1  value 18531 :1  value 18533 :1  value 18535 :2  value 18541 :1
value 18546 :1

```

ROI A8 :

Membro inferior direito:

```

Centro: {X=52,Y=88}
Minimo: 18461
Maximo: 18569
Mediana: 18524
Media: 18519
Desvio Padrao: 22,87247
Skewness: -0,485864348859067
Kurtosis: -0,232418177271032

```

Pixeis:

```

18479 18479 18478 18464 18492 18492 18512 18523 18522
18476 18461 18495 18494 18473 18491 18509 18502 18522
18483 18491 18497 18494 18510 18496 18524 18523 18518
18509 18506 18499 18506 18507 18522 18523 18532 18528
18517 18519 18520 18518 18523 18539 18527 18542 18540
18517 18524 18527 18532 18530 18533 18536 18537 18540
18524 18514 18538 18530 18528 18540 18546 18544 18543
18533 18529 18534 18532 18529 18545 18546 18552 18549
18546 18532 18530 18536 18542 18544 18552 18555 18569

```

Histograma:

```

value 18461 :1  value 18464 :1  value 18473 :1  value 18476 :1  value 18478 :1  value 18479 :2
value 18483 :1  value 18491 :2
value 18492 :2  value 18494 :2  value 18495 :1  value 18496 :1  value 18497 :1  value 18499 :1
value 18502 :1  value 18506 :2
value 18507 :1  value 18509 :2  value 18510 :1  value 18512 :1  value 18514 :1  value 18517 :2
value 18518 :2  value 18519 :1
value 18520 :1  value 18522 :3  value 18523 :4  value 18524 :3  value 18527 :2  value 18528 :2
value 18529 :2  value 18530 :3
value 18532 :4  value 18533 :2  value 18534 :1  value 18536 :2  value 18537 :1  value 18538 :1
value 18539 :1  value 18540 :3
value 18542 :2  value 18543 :1  value 18544 :2  value 18545 :1  value 18546 :3  value 18549 :1
value 18552 :2  value 18555 :1

```

value 18569 :1

Membro inferior esquerdo:

Centro: {X=238,Y=87}

Minimo E: 18518

Maximo E: 18620

Mediana: 18568

Media: 18568

Media: 18568

Desvio Padrao: 25,95934

Skewness: 0,0143032064323718

Kurtosis: -0,89758255277501

Pixeis:

18538	18542	18535	18550	18525	18521	18526	18525	18518
18567	18553	18553	18555	18534	18539	18544	18538	18520
18562	18557	18570	18563	18560	18552	18544	18530	18543
18567	18570	18572	18576	18564	18559	18542	18543	18539
18588	18577	18568	18569	18568	18566	18560	18556	18543
18592	18590	18584	18582	18564	18575	18571	18550	18551
18589	18596	18592	18594	18588	18581	18588	18578	18563
18588	18600	18598	18606	18620	18592	18588	18592	18589
18615	18608	18605	18610	18601	18604	18614	18607	18587

Histograma:

value 18518 :1	value 18520 :1	value 18521 :1	value 18525 :2	value 18526 :1	value 18530 :1
value 18534 :1	value 18535 :1	value 18538 :2	value 18539 :2	value 18542 :2	value 18543 :3
value 18544 :2	value 18550 :2	value 18551 :1	value 18552 :1	value 18553 :2	value 18555 :1
value 18556 :1	value 18557 :1	value 18559 :1	value 18560 :2	value 18562 :1	value 18563 :2
value 18564 :2	value 18566 :1	value 18567 :2	value 18568 :2	value 18569 :1	value 18570 :2
value 18571 :1	value 18572 :1	value 18575 :1	value 18576 :1	value 18577 :1	value 18578 :1
value 18581 :1	value 18582 :1	value 18584 :1	value 18587 :1	value 18588 :5	value 18589 :2
value 18590 :1	value 18592 :4	value 18594 :1	value 18596 :1	value 18598 :1	value 18600 :1
value 18601 :1	value 18604 :1	value 18605 :1	value 18606 :1	value 18607 :1	value 18608 :1
value 18610 :1	value 18614 :1	value 18615 :1	value 18620 :1		

ROI A9 :

Membro inferior direito:

Centro: {X=23,Y=109}

Minimo: 18528

Maximo: 18620

Mediana: 18562

Media: 18563

Desvio Padrao: 16,21342  
 Skewness: 0,610544074478325  
 Kurtosis: 0,989370005213339

Pixeis:

```
18536 18546 18550 18559 18551 18559 18556 18557 18558
18553 18548 18549 18549 18558 18563 18563 18562 18563
18556 18555 18553 18563 18559 18567 18562 18568 18575
18563 18561 18557 18559 18565 18565 18573 18568 18584
18551 18555 18561 18561 18566 18568 18574 18580 18588
18528 18549 18553 18571 18571 18573 18583 18583 18583
18540 18547 18559 18561 18572 18579 18576 18590 18596
18543 18546 18552 18555 18570 18583 18583 18583 18585
18533 18529 18554 18545 18579 18577 18589 18594 18620
```

Histograma:

```
value 18528 :1 value 18529 :1 value 18533 :1 value 18536 :1 value 18540 :1 value 18543 :1
value 18545 :1 value 18546 :2
value 18547 :1 value 18548 :1 value 18549 :3 value 18550 :1 value 18551 :2 value 18552 :1
value 18553 :3 value 18554 :1
value 18555 :3 value 18556 :2 value 18557 :2 value 18558 :2 value 18559 :5 value 18561 :4
value 18562 :2 value 18563 :5
value 18565 :2 value 18566 :1 value 18567 :1 value 18568 :3 value 18570 :1 value 18571 :2
value 18572 :1 value 18573 :2
value 18574 :1 value 18575 :1 value 18576 :1 value 18577 :1 value 18579 :2 value 18580 :1
value 18583 :6 value 18584 :1
value 18585 :1 value 18588 :1 value 18589 :1 value 18590 :1 value 18594 :1 value 18596 :1
value 18620 :1
```

Membro inferior esquerdo:

Centro: {X=266,Y=109}  
 Minimo E: 18579  
 Maximo E: 18683  
 Mediana: 18626  
 Media: 18628  
 Media: 18628  
 Desvio Padrao: 29,62748  
 Skewness: 0,163100536858515  
 Kurtosis: -1,25791286926065

Pixeis:

```
18635 18622 18628 18626 18618 18601 18594 18588 18587
18651 18634 18635 18625 18625 18600 18588 18584 18579
18638 18656 18641 18628 18623 18618 18613 18599 18581
18655 18661 18656 18635 18623 18605 18610 18592 18583
```

```

18663 18658 18653 18649 18622 18603 18609 18595 18587
18673 18669 18653 18659 18642 18610 18606 18604 18594
18671 18671 18673 18656 18658 18657 18609 18602 18594
18676 18672 18666 18666 18645 18638 18607 18605 18591
18683 18675 18671 18672 18633 18631 18621 18597 18599

```

Histograma:

```

value 18579 :1 value 18581 :1 value 18583 :1 value 18584 :1 value 18587 :2 value 18588 :2
value 18591 :1 value 18592 :1 value 18594 :3 value 18595 :1 value 18597 :1 value 18599 :2
value 18600 :1 value 18601 :1 value 18602 :1 value 18603 :1 value 18604 :1 value 18605 :2
value 18606 :1 value 18607 :1 value 18609 :2 value 18610 :2 value 18613 :1 value 18618 :2
value 18621 :1 value 18622 :2 value 18623 :2 value 18625 :2 value 18626 :1 value 18628 :2
value 18631 :1 value 18633 :1 value 18634 :1 value 18635 :3 value 18638 :2 value 18641 :1
value 18642 :1 value 18645 :1 value 18649 :1 value 18651 :1 value 18653 :2 value 18655 :1
value 18656 :3 value 18657 :1 value 18658 :2 value 18659 :1 value 18661 :1 value 18663 :1
value 18666 :2 value 18669 :1 value 18671 :3 value 18672 :2 value 18673 :2 value 18675 :1
value 18676 :1 value 18683 :1

```

ROI A10 :

Membro inferior direito:

```

Centro: {X=53,Y=146}
Minimo: 19061
Maximo: 19153
Mediana: 19119
Media: 19115
Desvio Padrao: 22,10062
Skewness: -0,600194378538893
Kurtosis: -0,396483037833779

```

Pixeis:

```

19066 19073 19085 19105 19109 19127 19123 19103 19119
19061 19100 19093 19105 19117 19117 19120 19130 19115
19067 19108 19089 19100 19115 19120 19119 19129 19122
19082 19084 19117 19105 19122 19118 19129 19134 19127
19088 19092 19105 19119 19124 19129 19134 19138 19137
19080 19089 19115 19115 19129 19134 19139 19141 19140
19074 19095 19110 19123 19132 19135 19144 19139 19140
19069 19104 19111 19129 19141 19141 19141 19142 19145
19083 19112 19107 19107 19125 19134 19141 19146 19153

```

Histograma:

```

value 19061 :1 value 19066 :1 value 19067 :1 value 19069 :1 value 19073 :1 value 19074 :1
value 19080 :1 value 19082 :1

```

```

value 19083 :1  value 19084 :1  value 19085 :1  value 19088 :1  value 19089 :2  value 19092 :1
value 19093 :1  value 19095 :1
value 19100 :2  value 19103 :1  value 19104 :1  value 19105 :4  value 19107 :2  value 19108 :1
value 19109 :1  value 19110 :1
value 19111 :1  value 19112 :1  value 19115 :4  value 19117 :3  value 19118 :1  value 19119 :3
value 19120 :2  value 19122 :2
value 19123 :2  value 19124 :1  value 19125 :1  value 19127 :2  value 19129 :5  value 19130 :1
value 19132 :1  value 19134 :4
value 19135 :1  value 19137 :1  value 19138 :1  value 19139 :2  value 19140 :2  value 19141 :5
value 19142 :1  value 19144 :1
value 19145 :1  value 19146 :1  value 19153 :1

```

Membro inferior esquerdo:

```

Centro: {X=240,Y=143}
Minimo E: 18966
Maximo E: 19000
Mediana: 18983
Media: 18981
Media: 18981
Desvio Padrao: 6,512488
Skewness: 0,698845162458699
Kurtosis: 0,339952562945563

```

Pixeis:

```

18984 18983 18987 18982 18984 18983 18976 18976 18971
18982 18978 18984 18984 18985 18981 18979 18973 18973
18975 18985 18987 18981 18987 19000 18975 18975 18971
18981 18991 18984 18983 18985 18998 18979 18973 18966
18984 18985 18983 18986 18983 18980 18976 18978 18975
18978 18980 18984 18987 18977 18979 18980 18975 18973
18975 18987 18973 18981 18979 18992 18975 18983 18975
18983 18982 18989 18984 18993 18993 18991 18987 18983
18982 18992 18985 18993 18992 18985 18974 18985 18983

```

Histograma:

```

value 18966 :1  value 18971 :2  value 18973 :5  value 18974 :1  value 18975 :8  value 18976 :3
value 18977 :1  value 18978 :3  value 18979 :4  value 18980 :3  value 18981 :4  value 18982 :4
value 18983 :9  value 18984 :8  value 18985 :7  value 18986 :1  value 18987 :6  value 18989 :1
value 18991 :2  value 18992 :3  value 18993 :3  value 18998 :1  value 19000 :1

```

ROI A11 :

Membro inferior direito:

```

Centro: {X=37,Y=174}

```

Mínimo: 18763  
 Máximo: 18871  
 Mediana: 18803  
 Média: 18803  
 Desvio Padrão: 28,46138  
 Skewness: 0,562864394125708  
 Kurtosis: -0,757367320036514

Píxeis:

```

18771 18773 18800 18819 18814 18831 18838 18871 18864
18771 18778 18774 18787 18812 18823 18832 18844 18858
18771 18778 18784 18811 18811 18830 18832 18861 18856
18763 18772 18806 18808 18784 18820 18835 18848 18848
18776 18769 18780 18806 18782 18816 18832 18838 18852
18768 18772 18776 18809 18798 18805 18812 18837 18833
18773 18773 18777 18794 18793 18798 18803 18823 18829
18766 18771 18784 18775 18784 18807 18801 18814 18824
18772 18770 18776 18785 18776 18790 18796 18805 18819
  
```

Histograma:

```

value 18763 :1 value 18766 :1 value 18768 :1 value 18769 :1 value 18770 :1 value 18771 :4
value 18772 :3 value 18773 :3
value 18774 :1 value 18775 :1 value 18776 :4 value 18777 :1 value 18778 :2 value 18780 :1
value 18782 :1 value 18784 :4
value 18785 :1 value 18787 :1 value 18790 :1 value 18793 :1 value 18794 :1 value 18796 :1
value 18798 :2 value 18800 :1
value 18801 :1 value 18803 :1 value 18805 :2 value 18806 :2 value 18807 :1 value 18808 :1
value 18809 :1 value 18811 :2
value 18812 :2 value 18814 :2 value 18816 :1 value 18819 :2 value 18820 :1 value 18823 :2
value 18824 :1 value 18829 :1
value 18830 :1 value 18831 :1 value 18832 :3 value 18833 :1 value 18835 :1 value 18837 :1
value 18838 :2 value 18844 :1
value 18848 :2 value 18852 :1 value 18856 :1 value 18858 :1 value 18861 :1 value 18864 :1
value 18871 :1
  
```

Membro inferior esquerdo:

Centro: {X=258,Y=172}  
 Mínimo E: 18673  
 Máximo E: 18776  
 Mediana: 18711  
 Média: 18713  
 Média: 18713  
 Desvio Padrão: 23,25699  
 Skewness: 0,468177973982498  
 Kurtosis: -0,192498776589586

Pixelis:

```
18776 18773 18752 18738 18729 18736 18729 18726 18734
18763 18739 18735 18752 18733 18730 18730 18731 18735
18736 18736 18749 18727 18735 18733 18725 18731 18728
18749 18711 18731 18726 18713 18717 18697 18697 18706
18735 18707 18709 18713 18714 18719 18718 18701 18712
18714 18705 18713 18706 18711 18690 18710 18701 18698
18704 18703 18696 18698 18691 18686 18701 18701 18701
18694 18691 18693 18692 18676 18695 18681 18687 18673
18709 18693 18692 18684 18680 18682 18680 18674 18677
```

Histograma:

```
value 18673 :1 value 18674 :1 value 18676 :1 value 18677 :1 value 18680 :2 value 18681 :1
value 18682 :1 value 18684 :1 value 18686 :1 value 18687 :1 value 18690 :1 value 18691 :2
value 18692 :2 value 18693 :2 value 18694 :1 value 18695 :1 value 18696 :1 value 18697 :2
value 18698 :2 value 18701 :5 value 18703 :1 value 18704 :1 value 18705 :1 value 18706 :2
value 18707 :1 value 18709 :2 value 18710 :1 value 18711 :2 value 18712 :1 value 18713 :3
value 18714 :2 value 18717 :1 value 18718 :1 value 18719 :1 value 18725 :1 value 18726 :2
value 18727 :1 value 18728 :1 value 18729 :2 value 18730 :2 value 18731 :3 value 18733 :2
value 18734 :1 value 18735 :4 value 18736 :3 value 18738 :1 value 18739 :1 value 18749 :2
value 18752 :2 value 18763 :1 value 18773 :1 value 18776 :1
```

ROI A12 :

Membro inferior direito:

Centro: {X=61,Y=228}

Minimo: 18337

Maximo: 18438

Mediana: 18375

Media: 18376

Desvio Padrao: 22,49611

Skewness: 0,596341806424503

Kurtosis: -0,423555559360807

Pixelis:

```
18404 18407 18416 18430 18438 18404 18407 18421 18410
18404 18397 18394 18403 18393 18405 18411 18397 18395
18378 18383 18378 18383 18404 18399 18404 18391 18396
18376 18377 18362 18378 18400 18372 18384 18382 18390
18360 18360 18365 18359 18378 18375 18358 18379 18383
18354 18359 18357 18363 18358 18363 18378 18375 18382
18354 18362 18355 18354 18357 18361 18371 18352 18361
18353 18348 18351 18352 18361 18356 18355 18367 18363
18339 18337 18346 18346 18357 18353 18361 18372 18359
```



Histograma:

```
value 18337 :1 value 18339 :1 value 18346 :2 value 18348 :1 value 18351 :1 value 18352 :2
value 18353 :2 value 18354 :3
value 18355 :2 value 18356 :1 value 18357 :3 value 18358 :2 value 18359 :3 value 18360 :2
value 18361 :4 value 18362 :2
value 18363 :3 value 18365 :1 value 18367 :1 value 18371 :1 value 18372 :2 value 18375 :2
value 18376 :1 value 18377 :1
value 18378 :5 value 18379 :1 value 18382 :2 value 18383 :3 value 18384 :1 value 18390 :1
value 18391 :1 value 18393 :1
value 18394 :1 value 18395 :1 value 18396 :1 value 18397 :2 value 18399 :1 value 18400 :1
value 18403 :1 value 18404 :5
value 18405 :1 value 18407 :2 value 18410 :1 value 18411 :1 value 18416 :1 value 18421 :1
value 18430 :1 value 18438 :1
```

Membro inferior esquerdo:

Centro: {X=241,Y=222}

Minimo E: 18298

Maximo E: 18367

Mediana: 18330

Media: 18331

Media: 18331

Desvio Padrao: 18,17313

Skewness: 0,269741451791419

Kurtosis: -0,95425696986949

Pixeis:

```
18356 18366 18356 18367 18360 18362 18354 18356 18357
18357 18355 18359 18347 18349 18356 18346 18339 18349
18365 18331 18337 18343 18347 18343 18340 18347 18357
18326 18325 18325 18348 18340 18341 18346 18339 18337
18328 18331 18323 18331 18329 18330 18336 18329 18334
18322 18318 18319 18323 18332 18332 18331 18320 18317
18323 18319 18319 18322 18322 18315 18318 18321 18320
18322 18321 18310 18314 18308 18308 18315 18306 18307
18319 18298 18303 18307 18306 18308 18303 18304 18303
```

Histograma:

```
value 18298 :1 value 18303 :3 value 18304 :1 value 18306 :2 value 18307 :2 value 18308 :3
value 18310 :1 value 18314 :1 value 18315 :2 value 18317 :1 value 18318 :2 value 18319 :4
value 18320 :2 value 18321 :2 value 18322 :4 value 18323 :3 value 18325 :2 value 18326 :1
value 18328 :1 value 18329 :2 value 18330 :1 value 18331 :4 value 18332 :2 value 18334 :1
value 18336 :1 value 18337 :2 value 18339 :2 value 18340 :2 value 18341 :1 value 18343 :2
value 18346 :2 value 18347 :3 value 18348 :1 value 18349 :2 value 18354 :1 value 18355 :1
```

```
value 18356 :4  value 18357 :3  value 18359 :1  value 18360 :1  value 18362 :1  value 18365 :1  
value 18366 :1  
value 18367 :1
```

## Anexo E

# Resultados da classificação obtidos com o programa desenvolvido

### E.1 Primeiro teste de KNN

```
+ + + + KNN + + + +
With k =1

@@@ Summary @@@
Numero total de Elementos Classificados: 480
Numero total de Verdadeiros Positivos: 7
Numero total de Verdadeiros Negativos: 429
Numero total de Falsos Positivos: 18
Numero total de Falsos Negativos: 26
exatidao: 0,908333
precisao positiva: 0,280000
precisao negativa: 0,942857
sensibilidade: 0,212121
especificidade: 13,000000

+ + + + KNN + + + +
With k =3

@@@ Summary @@@
Numero total de Elementos Classificados: 480
Numero total de Verdadeiros Positivos: 1
Numero total de Verdadeiros Negativos: 441
Numero total de Falsos Positivos: 6
Numero total de Falsos Negativos: 32
exatidao: 0,920833
precisao positiva: 0,142857
precisao negativa: 0,932347
sensibilidade: 0,030303
especificidade: 13,363636
```

```
+ + + + KNN + + + +
```

```
With k =5
```

```
@@@ Summary @@@
```

```
Numero total de Elementos Classificados: 480
```

```
Numero total de Verdadeiros Positivos: 1
```

```
Numero total de Verdadeiros Negativos: 443
```

```
Numero total de Falsos Positivos: 4
```

```
Numero total de Falsos Negativos: 32
```

```
exatidao: 0,925000
```

```
precisao positiva: 0,200000
```

```
precisao negativa: 0,932632
```

```
sensibilidade: 0,030303
```

```
especificidade: 13,424242
```

```
+ + + + KNN + + + +
```

```
With k =7
```

```
@@@ Summary @@@
```

```
Numero total de Elementos Classificados: 480
```

```
Numero total de Verdadeiros Positivos: 1
```

```
Numero total de Verdadeiros Negativos: 443
```

```
Numero total de Falsos Positivos: 4
```

```
Numero total de Falsos Negativos: 32
```

```
exatidao: 0,925000
```

```
precisao positiva: 0,200000
```

```
precisao negativa: 0,932632
```

```
sensibilidade: 0,030303
```

```
especificidade: 13,424242
```

```
+ + + + KNN + + + +
```

```
With k =9
```

```
@@@ Summary @@@
```

```
Numero total de Elementos Classificados: 480
```

```
Numero total de Verdadeiros Positivos: 0
```

```
Numero total de Verdadeiros Negativos: 444
```

```
Numero total de Falsos Positivos: 3
```

```
Numero total de Falsos Negativos: 33
```

```
exatidao: 0,925000
```

```
precisao positiva: 0,000000
```

```
precisao negativa: 0,930818
```

```
sensibilidade: 0,000000
```

```
especificidade: 13,454545
```

```
+ + + + KNN + + + +
```

```
With k =11
```

```
@@@ Summary @@@
Numero total de Elementos Classificados: 480
Numero total de Verdadeiros Positivos: 0
Numero total de Verdadeiros Negativos: 445
Numero total de Falsos Positivos: 2
Numero total de Falsos Negativos: 33
exatidao: 0,927083
precisao positiva: 0,000000
precisao negativa: 0,930962
sensibilidade: 0,000000
especificidade: 13,484848
```

```
+ + + + KNN + + + +
With k =13
```

```
@@@ Summary @@@
Numero total de Elementos Classificados: 480
Numero total de Verdadeiros Positivos: 0
Numero total de Verdadeiros Negativos: 445
Numero total de Falsos Positivos: 2
Numero total de Falsos Negativos: 33
exatidao: 0,927083
precisao positiva: 0,000000
precisao negativa: 0,930962
sensibilidade: 0,000000
especificidade: 13,484848
```

```
+ + + + KNN + + + +
With k =15
```

```
@@@ Summary @@@
Numero total de Elementos Classificados: 480
Numero total de Verdadeiros Positivos: 0
Numero total de Verdadeiros Negativos: 447
Numero total de Falsos Positivos: 0
Numero total de Falsos Negativos: 33
exatidao: 0,931250
precisao positiva: 0,000000
precisao negativa: 0,931250
sensibilidade: 0,000000
especificidade: 13,545455
```

```
+ + + + KNN + + + +
With k =17
```

```
@@@ Summary @@@
Numero total de Elementos Classificados: 480
Numero total de Verdadeiros Positivos: 0
Numero total de Verdadeiros Negativos: 447
```

```
Numero total de Falsos Positivos: 0
Numero total de Falsos Negativos: 33
exatidao: 0,931250
precisao positiva: 0,000000
precisao negativa: 0,931250
sensibilidade: 0,000000
especificidade: 13,545455
```

## E.2 Segundo teste de KNN

```
+ + + + KNN + + + +
With k =1

@@@ Summary @@@
Numero total de Elementos Classificados: 480
Numero total de Verdadeiros Positivos: 1
Numero total de Verdadeiros Negativos: 426
Numero total de Falsos Positivos: 21
Numero total de Falsos Negativos: 32
exatidao: 0,889583
precisao positiva: 0,045455
precisao negativa: 0,930131
sensibilidade: 0,030303
especificidade: 12,909091

+ + + + KNN + + + +
With k =3

@@@ Summary @@@
Numero total de Elementos Classificados: 480
Numero total de Verdadeiros Positivos: 1
Numero total de Verdadeiros Negativos: 445
Numero total de Falsos Positivos: 2
Numero total de Falsos Negativos: 32
exatidao: 0,929167
precisao positiva: 0,333333
precisao negativa: 0,932914
sensibilidade: 0,030303
especificidade: 13,484848

+ + + + KNN + + + +
With k =5

@@@ Summary @@@
Numero total de Elementos Classificados: 480
Numero total de Verdadeiros Positivos: 0
Numero total de Verdadeiros Negativos: 446
```

```
Numero total de Falsos Positivos: 1
Numero total de Falsos Negativos: 33
exatidao: 0,929167
precisao positiva: 0,000000
precisao negativa: 0,931106
sensibilidade: 0,000000
especificidade: 13,515152

+ + + + KNN + + + +
With k =7

@@@ Summary @@@
Numero total de Elementos Classificados: 480
Numero total de Verdadeiros Positivos: 0
Numero total de Verdadeiros Negativos: 447
Numero total de Falsos Positivos: 0
Numero total de Falsos Negativos: 33
exatidao: 0,931250
precisao positiva: 0,000000
precisao negativa: 0,931250
sensibilidade: 0,000000
especificidade: 13,545455

+ + + + KNN + + + +
With k =9

@@@ Summary @@@
Numero total de Elementos Classificados: 480
Numero total de Verdadeiros Positivos: 0
Numero total de Verdadeiros Negativos: 447
Numero total de Falsos Positivos: 0
Numero total de Falsos Negativos: 33
exatidao: 0,931250
precisao positiva: 0,000000
precisao negativa: 0,931250
sensibilidade: 0,000000
especificidade: 13,545455

+ + + + KNN + + + +
With k =11

@@@ Summary @@@
Numero total de Elementos Classificados: 480
Numero total de Verdadeiros Positivos: 0
Numero total de Verdadeiros Negativos: 447
Numero total de Falsos Positivos: 0
Numero total de Falsos Negativos: 33
exatidao: 0,931250
precisao positiva: 0,000000
```

```
precisao negativa: 0,931250
sensibilidade: 0,000000
especificidade: 13,545455
```

```
+ + + + KNN + + + +
With k =13
```

```
@@@ Summary @@@
Numero total de Elementos Classificados: 480
Numero total de Verdadeiros Positivos: 0
Numero total de Verdadeiros Negativos: 447
Numero total de Falsos Positivos: 0
Numero total de Falsos Negativos: 33
exatidao: 0,931250
precisao positiva: 0,000000
precisao negativa: 0,931250
sensibilidade: 0,000000
especificidade: 13,545455
```

```
+ + + + KNN + + + +
With k =15
```

```
@@@ Summary @@@
Numero total de Elementos Classificados: 480
Numero total de Verdadeiros Positivos: 0
Numero total de Verdadeiros Negativos: 447
Numero total de Falsos Positivos: 0
Numero total de Falsos Negativos: 33
exatidao: 0,931250
precisao positiva: 0,000000
precisao negativa: 0,931250
sensibilidade: 0,000000
especificidade: 13,545455
```

```
+ + + + KNN + + + +
With k =17
```

```
@@@ Summary @@@
Numero total de Elementos Classificados: 480
Numero total de Verdadeiros Positivos: 0
Numero total de Verdadeiros Negativos: 447
Numero total de Falsos Positivos: 0
Numero total de Falsos Negativos: 33
exatidao: 0,931250
precisao positiva: 0,000000
precisao negativa: 0,931250
sensibilidade: 0,000000
especificidade: 13,545455
```



## E.3 Terceiro teste de KNN

```
+ + + + KNN + + + +
With k =1

@@@ Summary @@@
Numero total de Elementos Classificados: 480
Numero total de Verdadeiros Positivos: 10
Numero total de Verdadeiros Negativos: 414
Numero total de Falsos Positivos: 33
Numero total de Falsos Negativos: 23
exatidao: 0,883333
precisao positiva: 0,232558
precisao negativa: 0,947368
sensibilidade: 0,303030
especificidade: 12,545455

+ + + + KNN + + + +
With k =3

@@@ Summary @@@
Numero total de Elementos Classificados: 480
Numero total de Verdadeiros Positivos: 2
Numero total de Verdadeiros Negativos: 444
Numero total de Falsos Positivos: 3
Numero total de Falsos Negativos: 31
exatidao: 0,929167
precisao positiva: 0,400000
precisao negativa: 0,934737
sensibilidade: 0,060606
especificidade: 13,454545

+ + + + KNN + + + +
With k =5

@@@ Summary @@@
Numero total de Elementos Classificados: 480
Numero total de Verdadeiros Positivos: 0
Numero total de Verdadeiros Negativos: 447
Numero total de Falsos Positivos: 0
Numero total de Falsos Negativos: 33
exatidao: 0,931250
precisao positiva: 0,000000
precisao negativa: 0,931250
sensibilidade: 0,000000
especificidade: 13,545455

+ + + + KNN + + + +
```

With k =7

@@@ Summary @@@

Numero total de Elementos Classificados: 480

Numero total de Verdadeiros Positivos: 0

Numero total de Verdadeiros Negativos: 447

Numero total de Falsos Positivos: 0

Numero total de Falsos Negativos: 33

exatidao: 0,931250

precisao positiva: 0,000000

precisao negativa: 0,931250

sensibilidade: 0,000000

especificidade: 13,545455

+ + + + KNN + + + +

With k =9

@@@ Summary @@@

Numero total de Elementos Classificados: 480

Numero total de Verdadeiros Positivos: 0

Numero total de Verdadeiros Negativos: 447

Numero total de Falsos Positivos: 0

Numero total de Falsos Negativos: 33

exatidao: 0,931250

precisao positiva: 0,000000

precisao negativa: 0,931250

sensibilidade: 0,000000

especificidade: 13,545455

+ + + + KNN + + + +

With k =11

@@@ Summary @@@

Numero total de Elementos Classificados: 480

Numero total de Verdadeiros Positivos: 0

Numero total de Verdadeiros Negativos: 447

Numero total de Falsos Positivos: 0

Numero total de Falsos Negativos: 33

exatidao: 0,931250

precisao positiva: 0,000000

precisao negativa: 0,931250

sensibilidade: 0,000000

especificidade: 13,545455

+ + + + KNN + + + +

With k =13

@@@ Summary @@@

Numero total de Elementos Classificados: 480

```
Numero total de Verdadeiros Positivos: 0
Numero total de Verdadeiros Negativos: 447
Numero total de Falsos Positivos: 0
Numero total de Falsos Negativos: 33
exatidao: 0,931250
precisao positiva: 0,000000
precisao negativa: 0,931250
sensibilidade: 0,000000
especificidade: 13,545455

+ + + + KNN + + + +
With k =15

@@@ Summary @@@
Numero total de Elementos Classificados: 480
Numero total de Verdadeiros Positivos: 0
Numero total de Verdadeiros Negativos: 447
Numero total de Falsos Positivos: 0
Numero total de Falsos Negativos: 33
exatidao: 0,931250
precisao positiva: 0,000000
precisao negativa: 0,931250
sensibilidade: 0,000000
especificidade: 13,545455

+ + + + KNN + + + +
With k =17

@@@ Summary @@@
Numero total de Elementos Classificados: 480
Numero total de Verdadeiros Positivos: 0
Numero total de Verdadeiros Negativos: 447
Numero total de Falsos Positivos: 0
Numero total de Falsos Negativos: 33
exatidao: 0,931250
precisao positiva: 0,000000
precisao negativa: 0,931250
sensibilidade: 0,000000
especificidade: 13,545455
```



## Anexo F

# Resultados da classificação obtidos com o programa Weka

### F.1 Primeiro teste de KNN

**Para k=1:**

```
=== Run information ===

Scheme:      weka.classifiers.lazy.IBk -K 1 -W 0 -A "weka.core.neighboursearch.LinearNNSearch -A
Relation:    data-roi_te
Instances:   2158
Attributes:  6
              imagem
              pe
              numero
              media_t
              mediana_t
              diagnostico
Test mode:   user supplied test set:  size unknown (reading incrementally)

=== Classifier model (full training set) ===

IB1 instance-based classifier
using 1 nearest neighbour(s) for classification

Time taken to build model: 0 seconds

=== Evaluation on test set ===

Time taken to test model on supplied test set: 0.08 seconds

=== Summary ===
```

```

Correctly Classified Instances      440          91.2281 %
Incorrectly Classified Instances    40           8.7719 %
Kappa statistic                    0.0529
Mean absolute error                 0.0881
Root mean squared error             0.296
Relative absolute error             92.1717 %
Root relative squared error         116.4208 %
Total Number of Instances          480

```

```
=== Detailed Accuracy By Class ===
```

	TP Rate	FP Rate	Precision	Recall	F-Measure	MCC	ROC Area
PRC Area Class							
0,074 d	0,065	0,026	0,154	0,065	0,091	0,058	0,519
0,934 n	0,974	0,935	0,935	0,974	0,954	0,058	0,519
Weighted Avg.	0,912	0,874	0,881	0,912	0,895	0,058	0,519
0,876							

```
=== Confusion Matrix ===
```

```

a   b   <-- classified as
2  29 |   a = d
11 438 |   b = n

```

### Para k=3:

```
=== Run information ===
```

```

Scheme:      weka.classifiers.lazy.IBk -K 3 -W 0 -A "weka.core.neighboursearch.LinearNNSearch -A \"wek
Relation:    data-roi_te
Instances:    2158
Attributes:   6
              imagem
              pe
              numero
              media_t
              mediana_t
              diagnostico
Test mode:    user supplied test set:  size unknown (reading incrementally)

```

```
=== Classifier model (full training set) ===
```

```

IB1 instance-based classifier
using 3 nearest neighbour(s) for classification

```

```
Time taken to build model: 0 seconds
```

```
=== Evaluation on test set ===
```

```
Time taken to test model on supplied test set: 0.09 seconds
```

```
=== Summary ===
```

```
Correctly Classified Instances      450          93.4211 %
Incorrectly Classified Instances    30           6.5789 %
Kappa statistic                    0.1506
Mean absolute error                 0.0849
Root mean squared error             0.2517
Relative absolute error             88.8474 %
Root relative squared error        98.9743 %
Total Number of Instances         480
```

```
=== Detailed Accuracy By Class ===
```

		TP Rate	FP Rate	Precision	Recall	F-Measure	MCC	ROC Area
PRC Area	Class							
0,155	d	0,097	0,005	0,600	0,097	0,167	0,223	0,624
0,948	n	0,995	0,903	0,938	0,995	0,966	0,223	0,624
Weighted Avg.		0,934	0,842	0,915	0,934	0,911	0,223	0,624

```
=== Confusion Matrix ===
```

```
a   b   <-- classified as
3  28 |   a = d
2 447 |   b = n
```

### Para k=5:

```
=== Run information ===
```

```
Scheme:      weka.classifiers.lazy.IBk -K 5 -W 0 -A "weka.core.neighboursearch.LinearNNSearch -A
Relation:     data-roi_te
Instances:    2158
Attributes:   6
              imagem
              pe
              numero
              media_t
              mediana_t
              diagnostico
Test mode:    user supplied test set:  size unknown (reading incrementally)
```

```
=== Classifier model (full training set) ===
```

```
IB1 instance-based classifier
using 5 nearest neighbour(s) for classification
```

```
Time taken to build model: 0 seconds
```

```
=== Evaluation on test set ===
```

```
Time taken to test model on supplied test set: 0.07 seconds
```

```
=== Summary ===
```

Correctly Classified Instances	445	92.3246 %
Incorrectly Classified Instances	35	7.6754 %
Kappa statistic	0.0768	
Mean absolute error	0.0935	
Root mean squared error	0.2539	
Relative absolute error	97.8164 %	
Root relative squared error	99.8511 %	
Total Number of Instances	480	

```
=== Detailed Accuracy By Class ===
```

	TP Rate	FP Rate	Precision	Recall	F-Measure	MCC	ROC Area
PRC Area							
Class							
0,143 d	0,065	0,014	0,250	0,065	0,103	0,097	0,651
0,952 n	0,986	0,935	0,935	0,986	0,960	0,097	0,651
Weighted Avg.	0,923	0,873	0,889	0,923	0,902	0,097	0,651
0,897							

```
=== Confusion Matrix ===
```

```
a  b  <-- classified as
2  29 |  a = d
6 443 |  b = n
```

### Para k=7:

```
=== Run information ===
```

```
Scheme:      weka.classifiers.lazy.IBk -K 7 -W 0 -A "weka.core.neighboursearch.LinearNNSearch -A \"wek
Relation:     data-roi_te
Instances:    2158
Attributes:   6
              imagem
              pe
              numero
```



```

media_t
mediana_t
diagnostico
Test mode: user supplied test set: size unknown (reading incrementally)

=== Classifier model (full training set) ===

IB1 instance-based classifier
using 7 nearest neighbour(s) for classification

Time taken to build model: 0 seconds

=== Evaluation on test set ===

Time taken to test model on supplied test set: 0.2 seconds

=== Summary ===

Correctly Classified Instances      444          92.1053 %
Incorrectly Classified Instances    36           7.8947 %
Kappa statistic                    0.1112
Mean absolute error                 0.1009
Root mean squared error             0.2485
Relative absolute error             105.5935 %
Root relative squared error         97.7309 %
Total Number of Instances          480

=== Detailed Accuracy By Class ===

      TP Rate  FP Rate  Precision  Recall   F-Measure  MCC      ROC Area
PRC Area  Class
0,097      0,019    0,273     0,097    0,143      0,128    0,747
0,184      d
0,981      0,903    0,937     0,981    0,959      0,128    0,747
0,966      n
Weighted Avg. 0,921    0,843    0,892     0,921    0,903      0,128    0,747
0,913

=== Confusion Matrix ===

  a   b  <-- classified as
 3  28 |   a = d
 8 441 |   b = n

```

### Para SVM:

```

=== Run information ===

```

```

Scheme:      weka.classifiers.functions.LibSVM -S 0 -K 2 -D 3 -G 0.0 -R 0.0 -N 0.5 -M 40.0 -C 1.0 -E 0
Relation:    data-roi_te-weka.filters.unsupervised.attribute.Remove-R1-3
Instances:   2158
Attributes:  3
              media_t
              mediana_t
              diagnostico
Test mode:   user supplied test set:  size unknown (reading incrementally)

=== Classifier model (full training set) ===

LibSVM wrapper, original code by Yasser EL-Manzalawy (= WLSVM)

Time taken to build model: 0.09 seconds

=== Evaluation on test set ===

Time taken to test model on supplied test set: 0.02 seconds

=== Summary ===

Correctly Classified Instances      449           93.2018 %
Incorrectly Classified Instances    31           6.7982 %
Kappa statistic                    0
Mean absolute error                 0.068
Root mean squared error             0.2607
Relative absolute error             71.1236 %
Root relative squared error         102.5373 %
Total Number of Instances          480

=== Detailed Accuracy By Class ===

                TP Rate  FP Rate  Precision  Recall   F-Measure  MCC      ROC Area
PRC Area  Class
                0,000    0,000    0,000     0,000    0,000     0,000    0,500
0,068      d
                1,000    1,000    0,932     1,000    0,965     0,000    0,500
0,932      n
Weighted Avg.  0,932    0,932    0,869     0,932    0,899     0,000    0,500
0,873

=== Confusion Matrix ===

  a  b  <-- classified as
  0 31 |  a = d
  0 449 |  b = n

```

**Para ANN=2:**

```
=== Run information ===
```

```

Scheme:      weka.classifiers.lazy.IBk -K 3 -W 0 -A "weka.core.neighboursearch.LinearNNSearch -A
Relation:    data-roi_te-weka.filters.unsupervised.attribute.Remove-R1-3
Instances:   2158
Attributes:  3
              media_t
              mediana_t
              diagnostico
Test mode:   user supplied test set:  size unknown (reading incrementally)

```

```
=== Classifier model (full training set) ===
```

```

IB1 instance-based classifier
using 3 nearest neighbour(s) for classification

```

```
Time taken to build model: 0 seconds
```

```
=== Evaluation on test set ===
```

```
Time taken to test model on supplied test set: 0.07 seconds
```

```
=== Summary ===
```

```

Correctly Classified Instances      449           93.2018 %
Incorrectly Classified Instances     31           6.7982 %
Kappa statistic                     0
Mean absolute error                  0.068
Root mean squared error              0.2607
Relative absolute error              71.1236 %
Root relative squared error          102.5373 %
Total Number of Instances           480

```

```
=== Detailed Accuracy By Class ===
```

		TP Rate	FP Rate	Precision	Recall	F-Measure	MCC	ROC Area
PRC Area	Class							
		0,000	0,000	0,000	0,000	0,000	0,000	0,500
0,068	d							
		1,000	1,000	0,932	1,000	0,965	0,000	0,500
0,932	n							
Weighted Avg.		0,932	0,932	0,869	0,932	0,899	0,000	0,500
0,873								

```
=== Confusion Matrix ===
```

```

a  b  <-- classified as
0  31 |  a = d

```

|| 0 449 | b = n